

MACHINE LEARNING LAB



- Master courses 2020-2021, lecturer Ashot Chilingarian
 - Yerevan Physics Institute, Armenia

Big Data is more science than data!

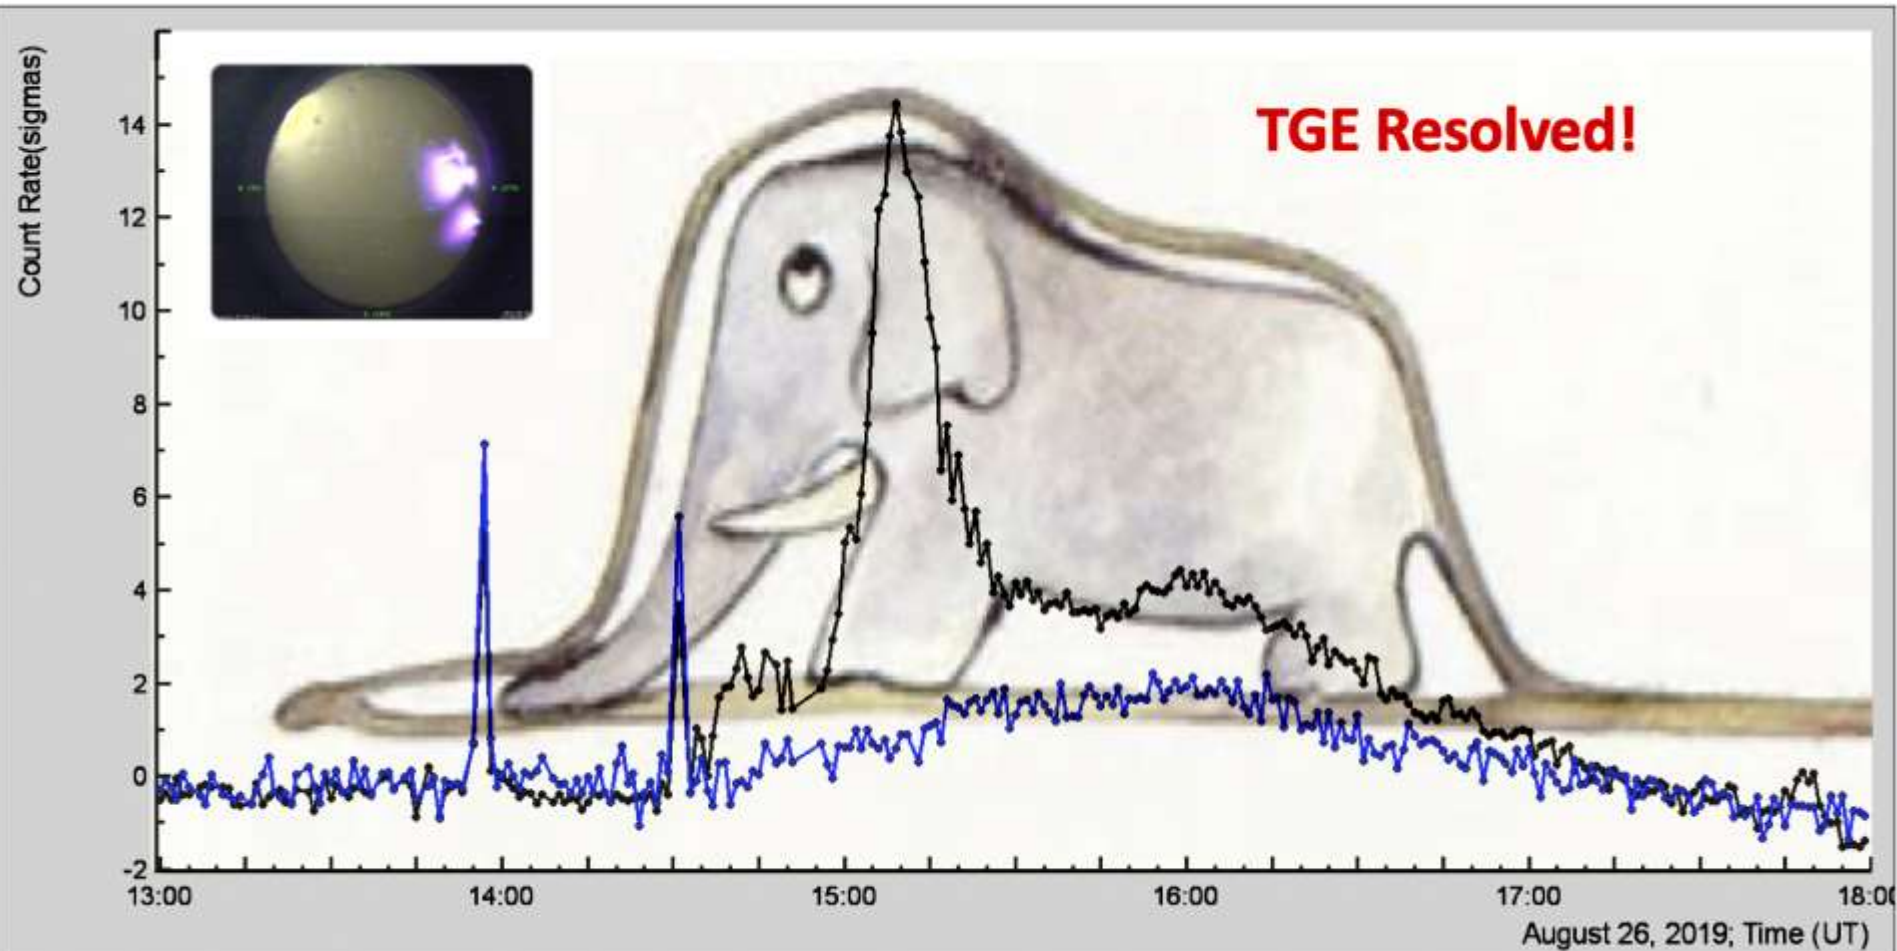
- Modeling a process by studying or wondering its dynamics and way how humanity understand this world and its place in it!
- У физики и машинного обучения есть нечто общее: обе области заняты наблюдениями и построением моделей, предсказывающих результаты последующих наблюдений.
- Formal Hypothesis construction and making algorithm for each hypothesis.
- Introducing of uncertainty regarding data and forecasts.
- Coding; verification and validation and
- A clear understanding of the limitations of the model.
- An understanding of the mathematical proof and the whole abstract logic on which the proof is based.

Storing experimental data in a “science cloud” has some advantages, such as making information more accessible to a wider scientific community.



In the coming decade, big projects like the Large Hadron Collider (LHC) and the Square Kilometre Array (SKA) are each expected to produce an exabyte of data yearly, which is about 20 times the digital content of all the written works throughout human history.

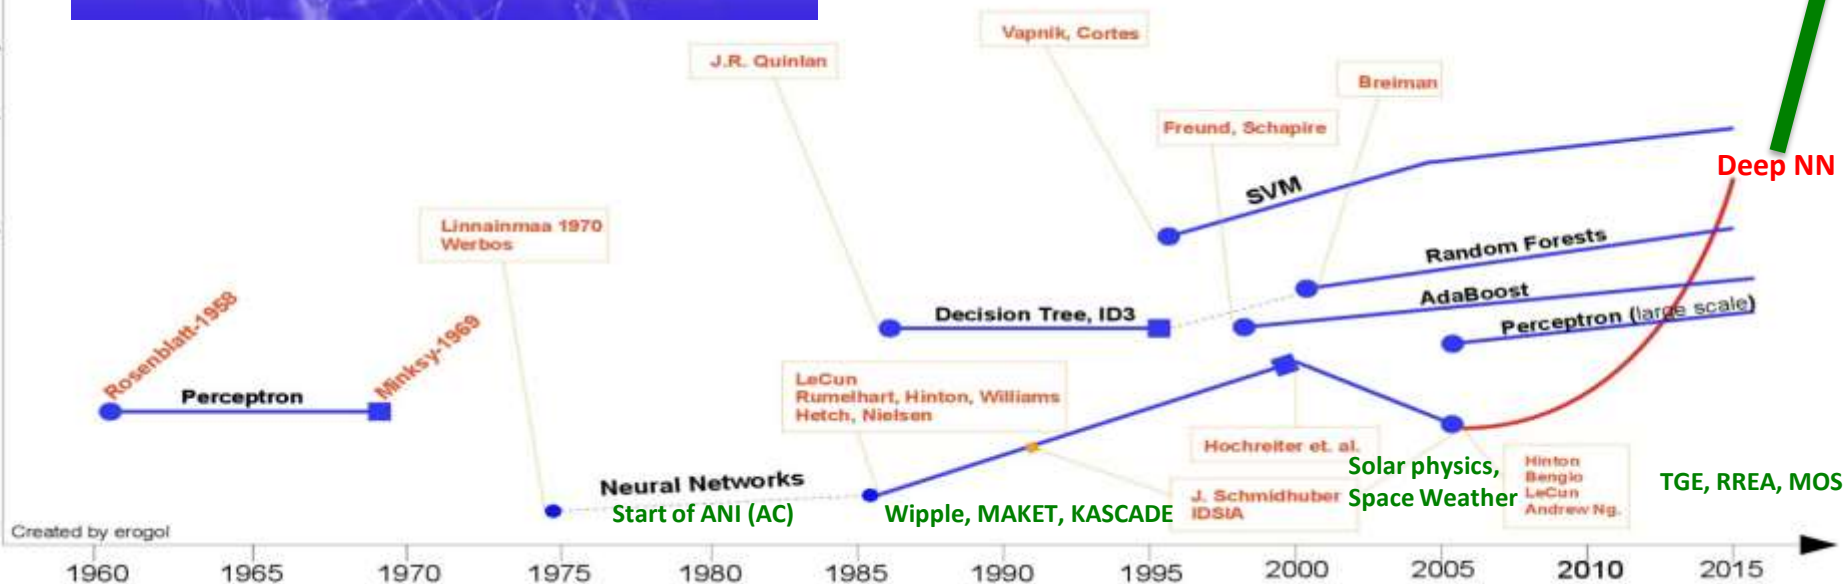
How to make Discovery?



Machine Learning not only in High-Energy Astrophysics (Astroparticle Physics)



Subjective Popularity



Tesla is developing a NN training computer called Dojo to process truly vast amounts of video data. An exaFLOP is one quintillion (10^{18}) floating-point operations per second, or 1,000 petaFLOPS.



Что такое направленная эволюция и почему это интересно: Профессор Калифорнийского технологического института, биоинженер и биохимик Фрэнсис Арнольд стала одной из немногих женщин-лауреатов Нобелевской премии.

- Она также применяла линейную регрессию — математическую модель, которая позволяла рассчитать, какие именно способы рекомбинации генов помогут создать наиболее устойчивые новые белки. С помощью машинного обучения модель удалось научить на небольшой выборке молекул, какие сочетания генов жизнеспособны и могут нести полезные функции, а какие нет — и это ускорило процесс «направленной эволюции» в разы по сравнению с селекцией «вручную»;
- Благодаря методикам Арнольд — а первая научная работа, описывающая то, за что она получила Нобелевскую премию, вышла еще в 1993 году — уже произвели множество полезных энзимов: они сейчас используются для создания разных продуктов, от стиральных порошков до биотоплива и лекарств. Больше всего Фрэнсис гордится разработкой на базе ее метода препарата Янувия фармацевтического концерна Merck & Co: это лекарство, которое помогает диабетикам, раньше производилось с использованием токсичных металлов. Арнольд рада, что ее открытие помогло уменьшить количество вредных выбросов и сделать продукт более безопасным;
- В начале 2020 года твиттер поразило [заявление](#) Фрэнсис Арнольд: 2 января она досрочно вернулась с новогодних каникул и сообщила, что отзывает опубликованную в мае 2019 года статью в журнале Science.
- Это поразительный пример честности в научном мире. В журнале Nature в 2016 году опубликовали шокирующие [цифры](#): результаты около 70% научных работ, одобренных рецензентами и напечатанных в качественных научных журналах, другие ученые воспроизвести не смогли. Это значит, что почти две трети современной науки находится в «серой зоне»: может, это правда, а может, и нет.

Можно сильно улучшить работу обычного сельскохозяйственного комбайна, если использовать нейросетки для распознавания культур и препятствий и робота для автопилотирования. Всё это (кроме процессоров Nvidia и ещё части железа) — наша разработка.



[Cognitive Pilot](#) Делаем ИИ-системы управления наземным транспортом

Сельскохозяйственный комбайны регулярно перемалывают людей, врезаются в тракторы и бегущие через поле столбы ЛЭП

- один рулит (держит кромку),
- второй управляет мотовилом, ветрами, барабанами,
- Третий в это время может делать отгрузку на ходу в грузовик,
- Четвёртый следит за препятствиями,
- В эпоху СССР в кабине было двое, потом остался один.

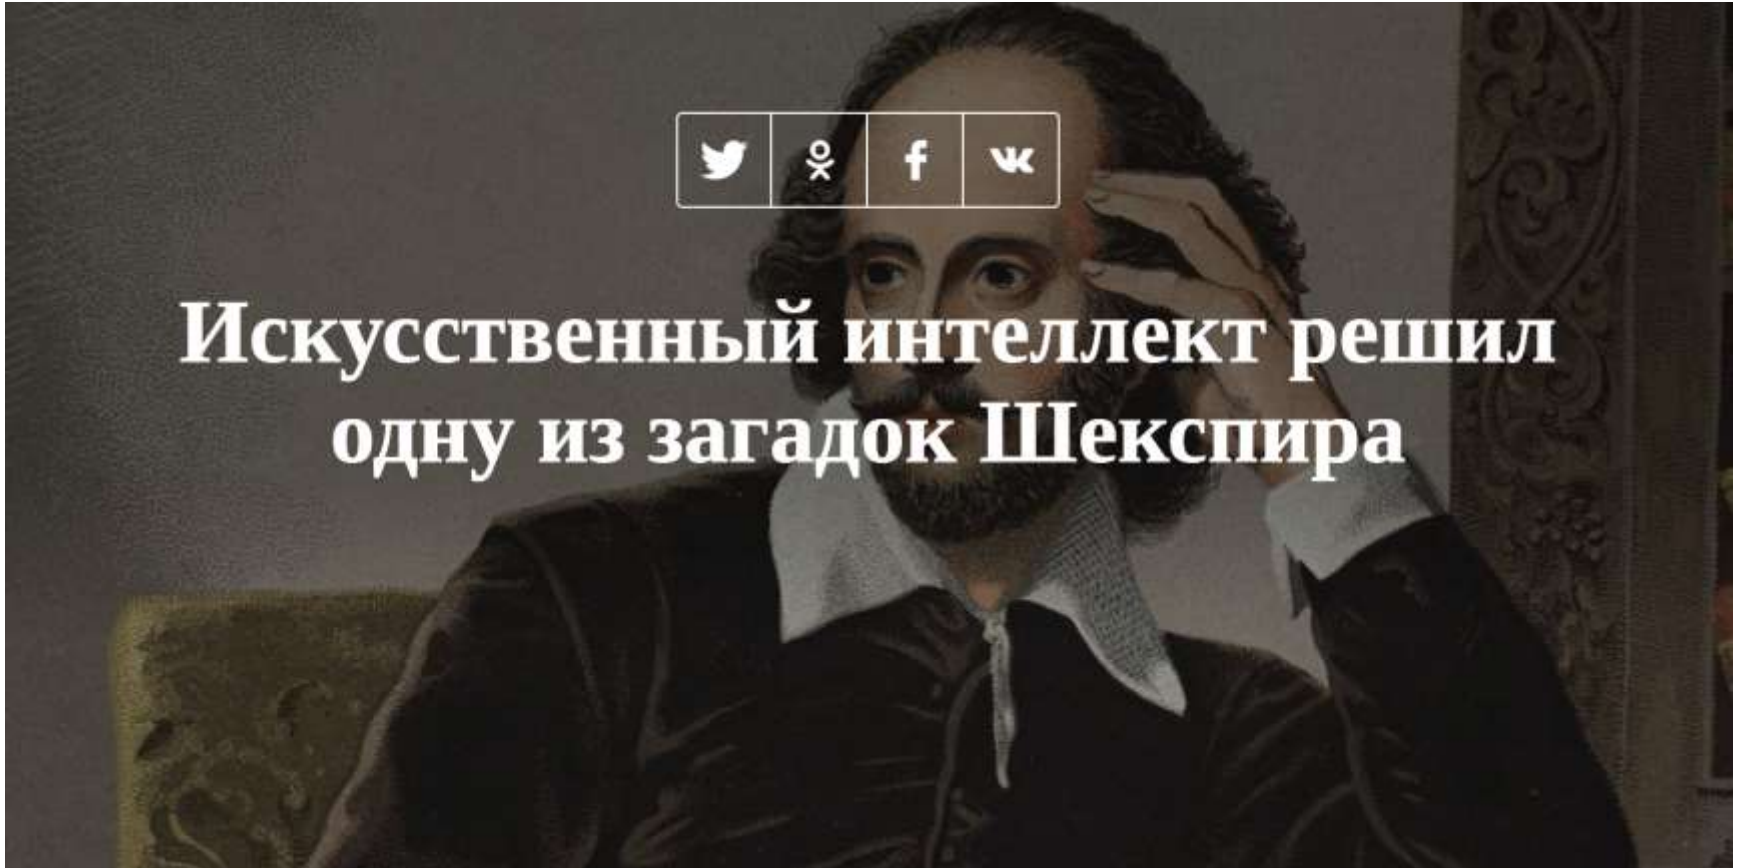
Отдельное подразделение занимается обучением нейросетей


- где какая культура,
- как выглядит полёгшая пшеница и так далее,
- Вычислительные модули на каждом комбайне автономные,
- Человек полностью разгружен. Он включает систему, отпускает руль, в лучшем случае контролирует работу машины, в худшем — сидит в телефоне,
- Роботы убирали злаковые: пшеницу, ячмень, овёс, рожь в южных регионах

В ряде случаев соавтор Джон Флетчер заканчивал фрагмент, начатый Шекспиром. Отмечается, что в создании «Генрих VIII» также участвовал писатель Филипп Мэссинджер.



Искусственный интеллект решил одну из загадок Шекспира






AR-очки Facebook получают функцию «суперслуха»



По мнению разработчиков, возможности виртуальной и дополненной реальности постепенно приближаются к реализации **«социального присутствия»**, когда человек может быстро и эффективно переместиться на учебу или работу, оставаясь дома. Например, при разговоре в шумном кафе, микрофоны устройства будут считывать все лишние звуки, вроде разговоров посторонних людей и звона посуды, а громкость собеседника будет увеличена и качество улучшена с помощью программного обеспечения. AR-очки все еще должны научиться использовать встроенные датчики и камеры для анализа геометрии помещения с помощью ИИ, а затем выводить виртуальную информацию определенным образом, чтобы пользователь «ощущал» реалистичный источник звука.

A new acoustic imaging technique uses a disordered set of plastic spheres to amplify short-wavelength sound waves in combination with machine learning to reduce the complexity and computational power needed for high-resolution imaging. This drawing shows the 8×8 array of speakers producing the audio equivalent of an image



Working first in the absence of the intermediate spheres, the algorithms performed poorly. However, in the presence of the spheres, the algorithm aiming to reconstruct the images did so effectively, and the one aiming to classify the digits achieved an accuracy of 79.4%.

Main principles

- Solving problems is human role in Universe!
- Intelligence SW includes: fluid intelligence - the ability to think logically, perceive and remember new things, solve new unusual problems; and crystallized intelligence - the accumulated experience and the ability to use the acquired knowledge and skills.
- Networks of simple elements make a great job!
- Training of network is a main strategy of problem solving;
- Evolution of live haver connections with evolution of universe;
- We have to avoid overtraining!

Statistics basics

- Summary and descriptive statistics, average, variance, covariance, correlation.
- Fundamentals of probability theory: fundamentals, expectation, calculus of probabilities, Bayes theorem, conditional probability.
- Probability distribution functions - uniform, normal, binomial, chi-square, student distribution, central limit theorem.
- Probabilistic distances;
- Random search methods;
- Sampling, measurement, error, random number generator.
- Hypothesis testing, testing, confidence interval, P-value.
- t-test
- Linear regression, regularization.

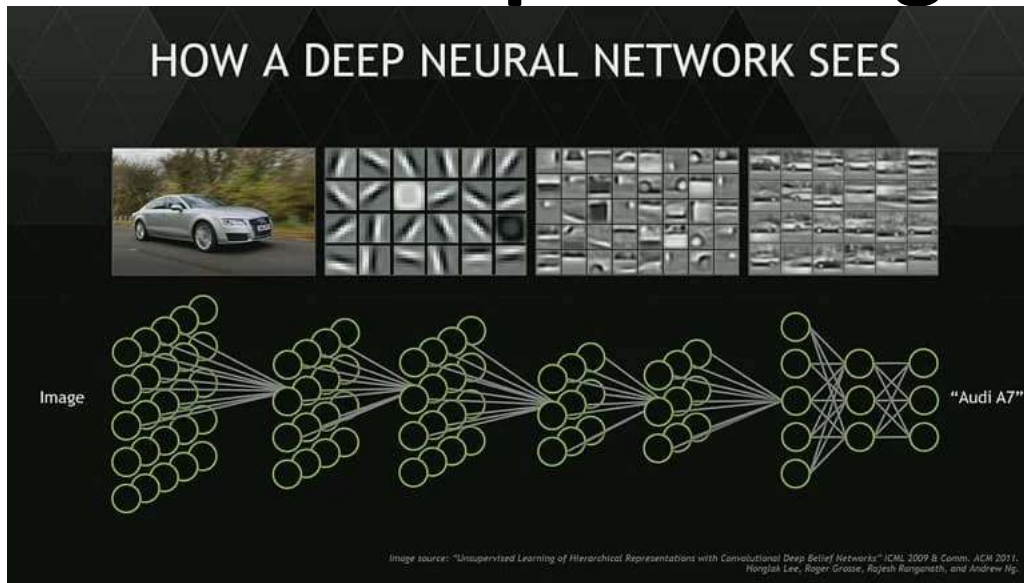
Definition of II

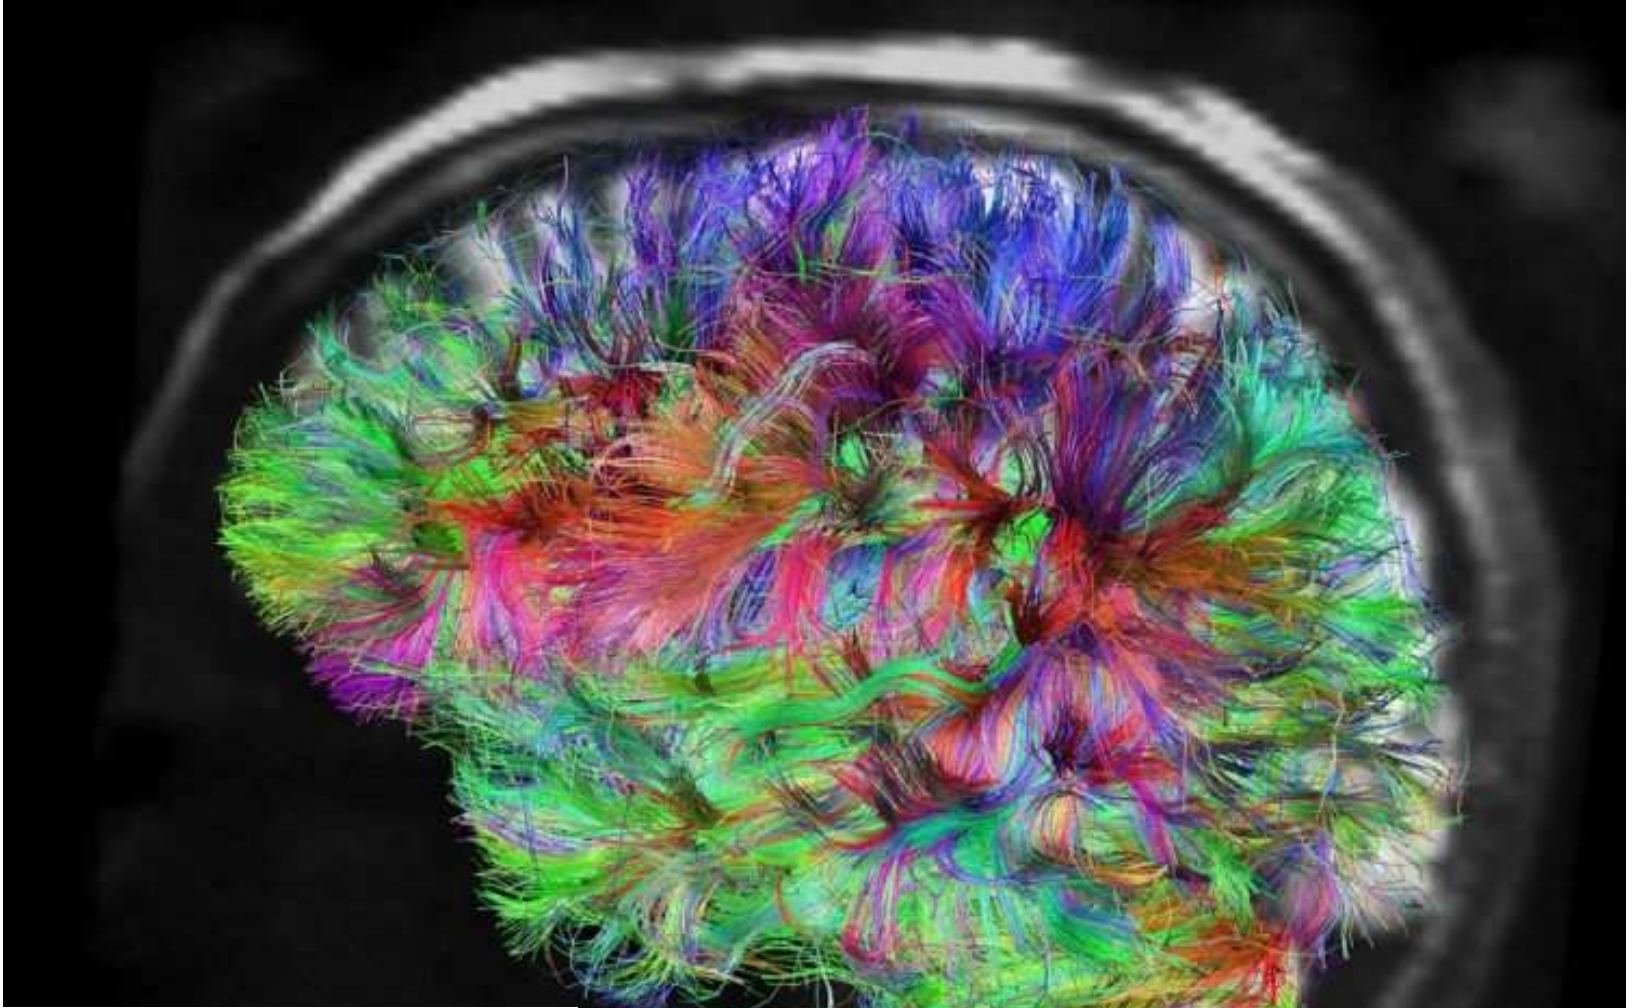
- *Все вышесказанное — не просто мой очередной призыв к читателям канала «Малоизвестное интересное». Это преамбула к 60ти страничному «манифесту» [On the Measure of Intelligence](#), на днях опубликованном **Франсуа Шнолле** — известным исследователем ИИ в компании Google, создателем библиотеки глубокого обучения Keras и соразработчиком фреймворка машинного обучения TensorFlow.*
- Интеллект измеряется НЕ способностями агента достигать сложных целей в широком диапазоне изменчивости внешней среды, а эффективностью приобретения навыков.
- В новом определении интеллекта делается упор на следующих критических понятиях, подлежащих учету при характеристике интеллектуальных систем: *ограничения задачи (score), сложности обобщения (generalization difficulty), априорная информация (priors) и опыт (experience).*
- Представлен новый корпус абстракций и рассуждений *Abstraction and Reasoning Corpus (ARC)*, построенный на явном наборе уже имеющихся у интеллектуального агента знаний и опыта с тем, чтобы соотносить его как можно ближе к собственным человеку знаниям и опыту.

Machine Learning and deep learning: Context-dependent pre-trained deep neural networks for large-vocabulary speech recognition

- Чтобы понять, что такое deep learning, нужно отделить его от других дисциплин в сфере искусственного интеллекта. Одна из них — машинное обучение, когда компьютер извлекает знания через управляемый опыт. Обычно в этом случае человек помогает машине учиться, подбрасывая ей сотни или тысячи учебных примеров и вручную исправляя ошибки.
- Хотя машинное обучение доминирует в сфере ИИ, у него есть свои проблемы. Прежде всего, оно требует колоссального времени. Кроме того, пока компьютер полагается на человеческую изобретательность, на умение человека придумывать абстракции, это нельзя назвать в полной мере машинным интеллектом.
- «Глубокое обучение» по большей части не нуждается в человеке-операторе. Оно подразумевает, например, создание масштабных нейросетей, которые позволяют компьютеру учиться и «думать» самостоятельно, не прибегая к прямому человеческому вмешательству.
- «То, что компьютер узнает при помощи алгоритмов deep learning — это скорее абстрактные представления концепций, — говорит Бенджио. — Deep learning основано на том, что у людей есть несколько типов представления идей: на нижних уровнях самые простые, на верхних — более сложные абстракции. Представляя информацию этим абстрактным способом, машине легче прийти к своим обобщениям».
- Российская нейросеть предрекла победу нынешнему президенту Соединенных Штатов [Дональду Трампу](#) на предстоящих выборах главы Белого дома. Уточняется, что нейросеть создали разработчики из Перми.

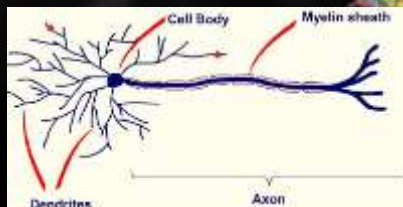
Как работает нейронная сеть? Что такое deep learning?





The Human Brain

- Contains 10,000 different types of neurons
- Contains 100 billion neurons
- Each neuron communicates with 5,000-200,000 other neurons to make one trillion neuronal connections.

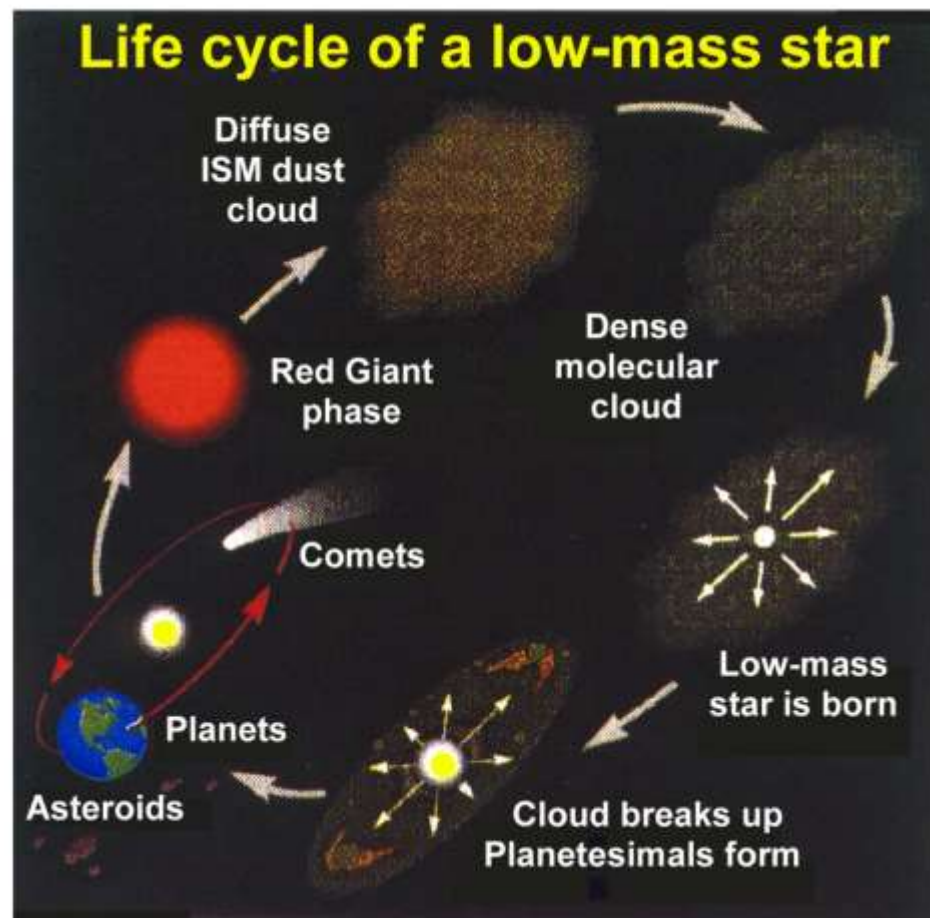


https://www.creativitypost.com/article/to_boost_brain_health_and_performance_harness_neuroplasticity_the_right_way

Human brain is a highly dynamic and constantly reorganizing system.

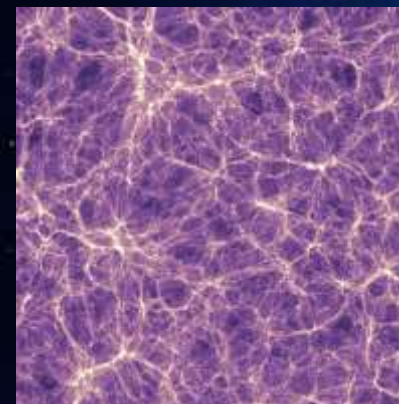
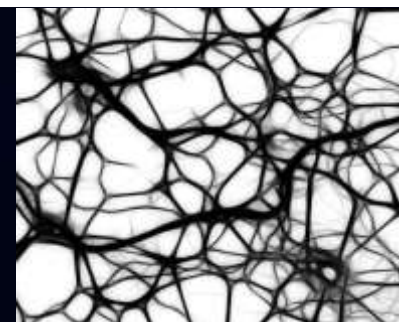
1. The central concept is the brain's lifelong capacity to change and rewire itself in response to the stimulation of learning and experience (neuroplasticity);
2. By solving problems (in physics) one can repeatedly stimulate the same area of the brain, which strengthens existing neural connections and creates new ones. Over time, the brain can become more efficient, requiring less effort to do the same job;
3. Continuous learning helps to fight against age-related decline and potential dementia pathology by increasing the connections between neurons, increasing cellular metabolism, and increasing the production a substance produced by the body to help maintain and repair neurons;
4. Do you know that London taxi drivers have a larger hippocampus than London bus drivers? Ask why or find yourself!

Мозгом Больцмана называется гипотетически возможная субстанция (объект), возникающая в результате флуктуаций физического вакуума, осознавшая себя и способная наблюдать за окружающим миром.



только наличие наблюдателя (мозга Больцмана) упорядочивает окружающий мир. До появления стороннего наблюдателя Вселенная в обязательном порядке является хаотической.

Deep Density Displacement Model (D3M), which learns from a set of prerun numerical simulations, predicts the nonlinear large-scale structure of the Universe. Note the connections between galaxies: are they of the same purpose as in brain?



We show that D3M is able to accurately extrapolate far beyond its training data and predict structure formation for significantly different cosmological parameters.

<https://doi.org/10.1073/pnas.1821458116>

Machine learning: Measurements, Decisions and Predictions

- 1. Decision making in random noisy environments: driver on the street, investor in the market, customer in the supermarket; student choosing profession, traveler choosing the rout, medical diagnostics, etc...**
- 2. Pattern recognition: $N \times N$ picture; binary (black and white) or vector (color) in each of thousands (millions) of pixels: monitor crime on the streets, find a person; read a drawing, etc...**
- 3. ML is not magic producing results on any input! you have to study math and statistics!**
- 4. New algorithms and expert knowledge of the domain are in great need!**
- 5. Maximal salary in IT sector: no problem with jobs in coming decades;**
- 6. “Future of Armenia depends on ML” Armen Sargsyan!**

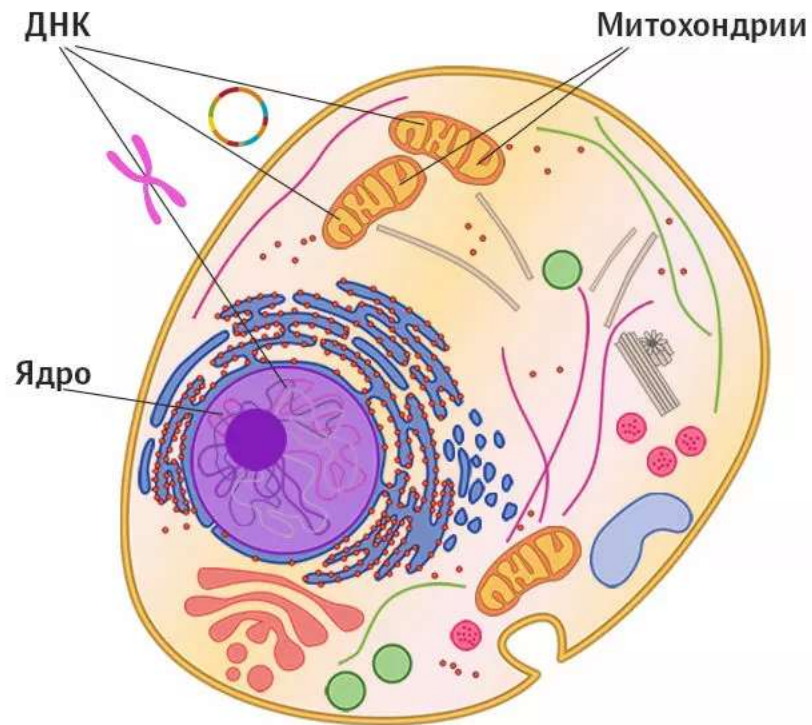
Domains

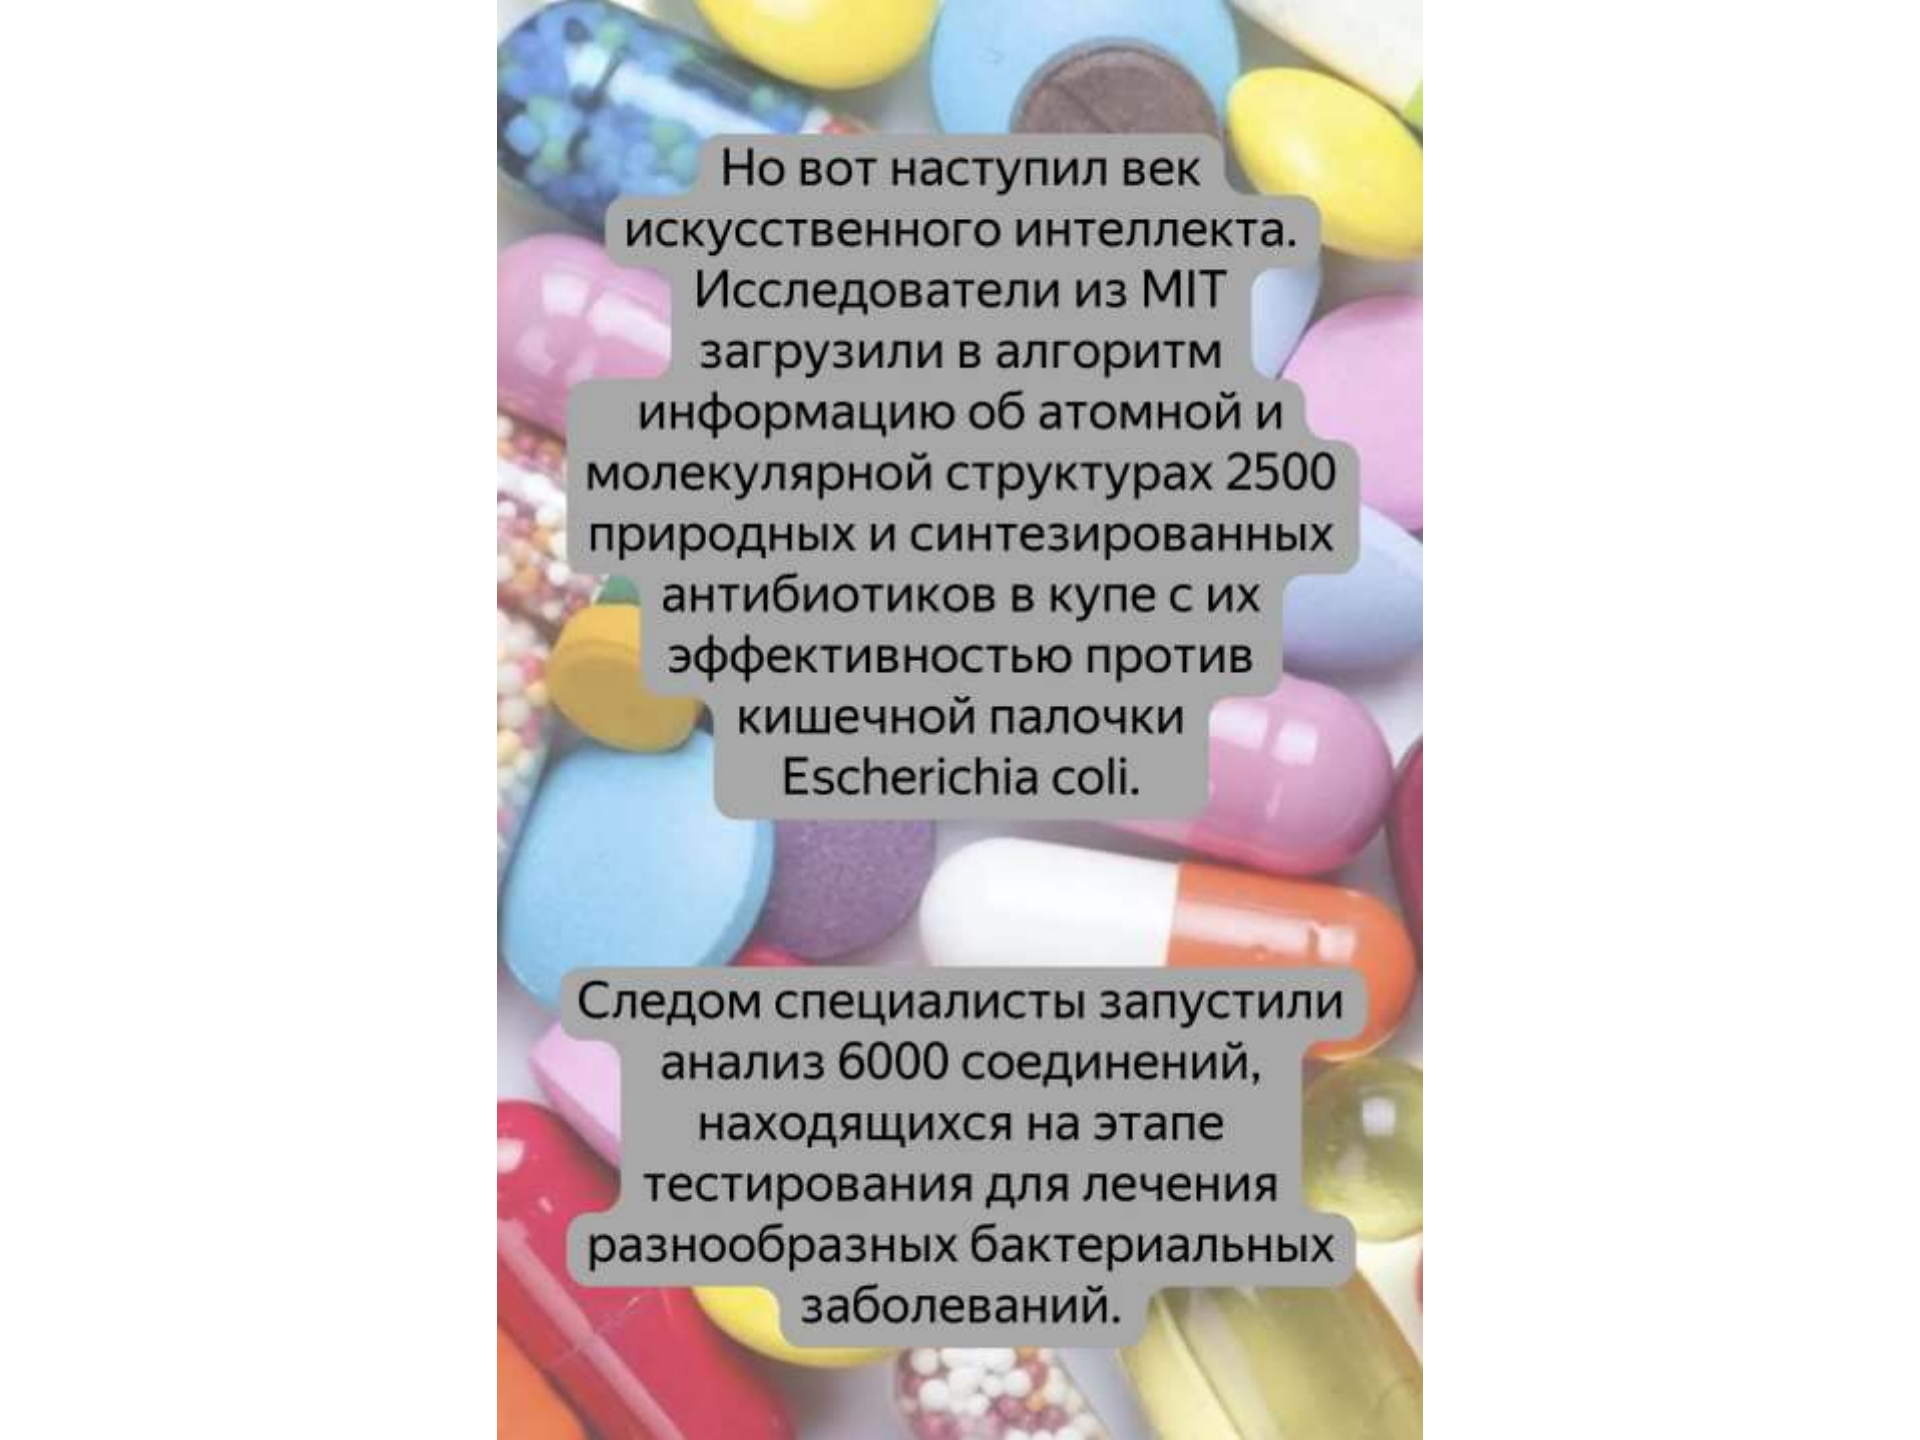
1. Speech recognition: automatic answering services;
2. Automatic control in mass production: check wrong pizza; and many others;
3. AI algorithms scanning data bases of all patients died from any diseases and finding optimal strategy of curing patient;
4. Optimal strategy of getting profit on highly violent stock markets: what and when to buy, when to sell, how to put margins!
5. Transport: optimal routes in city, fast response to traffic jams, navigators, safety...
6. Big brother watching streets to prevent crime!
7. Education: personalize learning programs;
8. истребителями шестого поколения речь идёт о максимальной роботизации систем с минимальным участием людей, о создании нейросети.
9. **Ученым Массачусетского технологического института (MIT) удалось обнаружить сразу несколько новых антибиотиков с помощью нейросети, что стало уникальным достижением в истории медицины. Одна из находок — халицин — оказалась в состоянии уничтожить даже те бактерии, которые были устойчивы ко всем существующим лекарственным препаратам.** нейросети предложили просканировать несколько библиотек химических соединений, в которых насчитывается более 107 млн молекул, для обнаружения тех, которые в теории могут соответствовать необходимым требованиям. Нейросетью были обнаружены 23 молекулы, подходящие под заданные параметры. Из них ученые отобрали девять, в том числе халицин.

Tesla хочет использовать весь парк выпущенных машин для обучения ИИ

- Она описывает метод, позволяющий классифицировать потенциальные данные для тренировки локально, до их передачи. Если программа оценивает данные как потенциально пригодные для ИИ, то дает команду передавать их по беспроводной сети. Затем они используются для улучшения автопилота.
- компания Илона Маска оснащает все свои электромобили набором сенсоров для сбора дорожной информации, продает их и тестирует систему беспилотного управления в «скрытом режиме»;
- Обычно производительность систем глубокого обучения ограничена как минимум отчасти качеством тренировочных данных. Во многих случаях значительные ресурсы вкладываются в сбор, исправление и аннотирование этих данных. Усилия, которые требуются для создания наборов данных, зачастую значительны. Более того, часто сложно собрать данные для определенных целей, которые требуются для улучшения модели машинного обучения».
- Речь идет об интеллектуальном обучении центральной нейронной сети — собираемые каждой машиной данные классифицируются локально, бортовым компьютером, и оцениваются на предмет ценности для обучения ИИ. В ЦОД Tesla передаются только ценные данные. Они и используются для улучшения автопилота;

У человека один из самых маленьких митохондриальных геномов, всего 16,5 тысячи пар нуклеотидов, 37 генов. Для сравнения: у наземных растений — сотни тысяч пар. мтДНК наследуется только от матери к дочери.





Но вот наступил век
искусственного интеллекта.
Исследователи из MIT
загрузили в алгоритм
информацию об атомной и
молекулярной структурах 2500
природных и синтезированных
антибиотиков в купе с их
эффективностью против
кишечной палочки
Escherichia coli.

Следом специалисты запустили
анализ 6000 соединений,
находящихся на этапе
тестирования для лечения
разнообразных бактериальных
заболеваний.

Human genome contains 3 billion coding elements

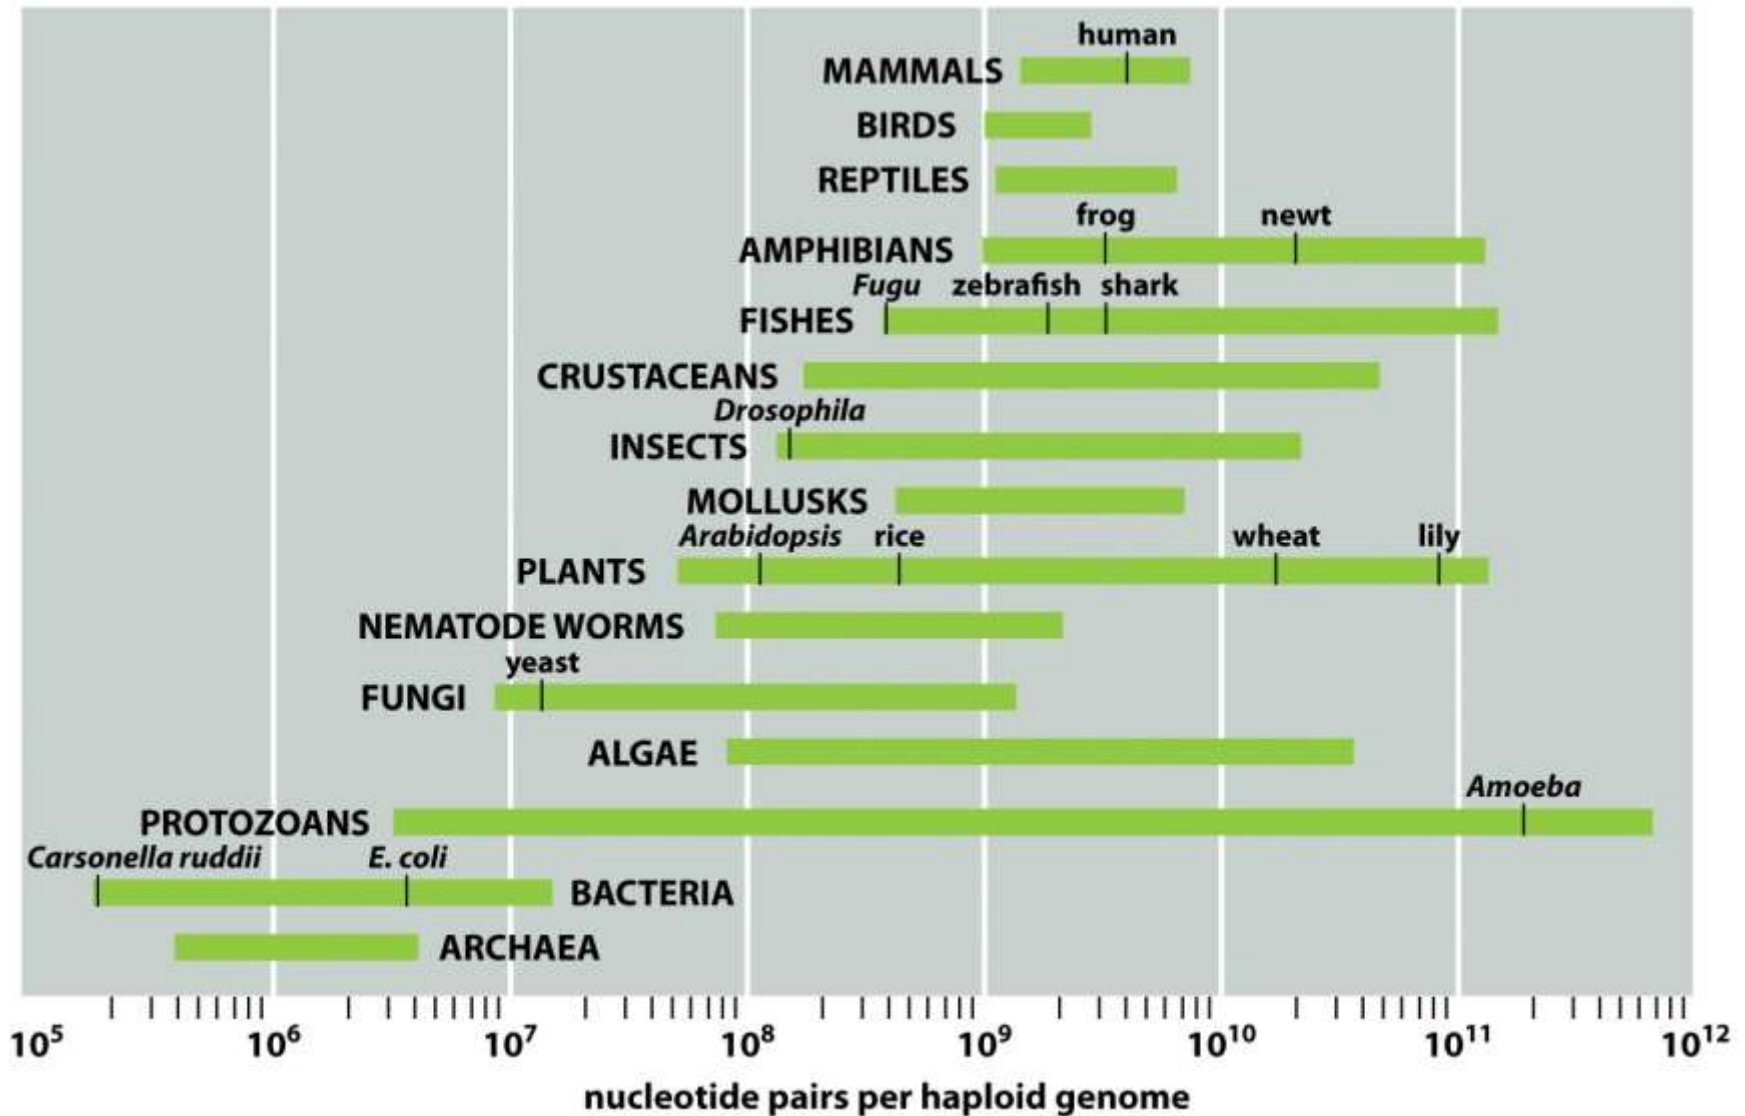



Figure 1-41 Essential Cell Biology 3/e (© Garland Science 2010)

Largest Chip Ever Built

- 46,225 mm² silicon
- 1.2 trillion transistors
- 400,000 AI optimized cores
- 18 Gigabytes of On-chip Memory
- 9 PByte/s memory bandwidth
- 100 Pbit/s fabric bandwidth
- TSMC 16nm process



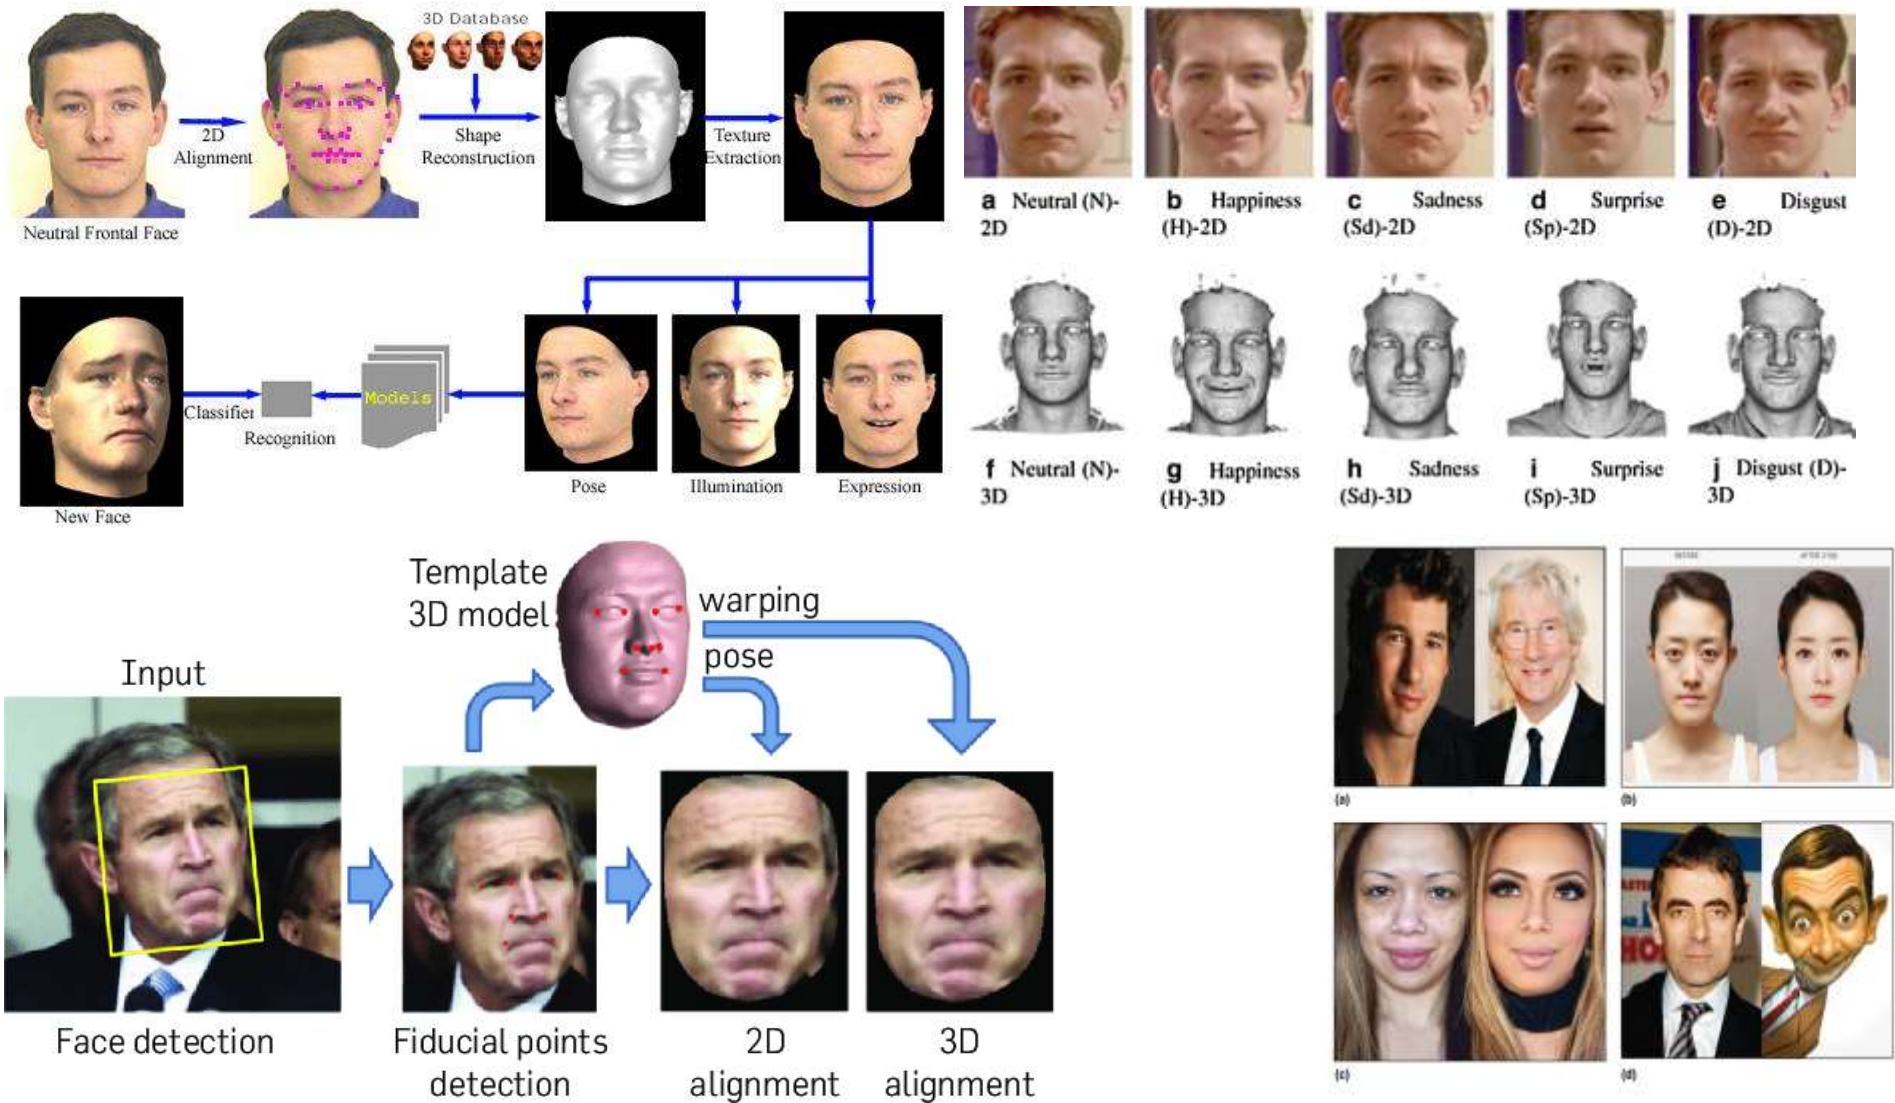
Cerebras — Cerebras Wafer Scale Engine

1. Каждый кристалл Cerebras WSE содержит 1,2 трлн транзисторов, организованных в 400 000 ИИ-оптимизированных вычислительных ядер и 18 Гбайт локальной распределённой памяти SRAM;
2. Всё это связано ячеистой сетью с общей производительностью 100 петабит в секунду. Пропускная способность памяти достигает 9 Пбайт/с;
3. В сравнении с самыми современными графическими ядрами чип Cerebras обеспечивает в 3000 раз больший объём памяти на кристалле и в 10 000 большую скорость обмена с памятью;
4. Вычислительные ядра Cerebras — SLAC (Sparse Linear Algebra Cores) — полностью программируемые и могут быть оптимизированы для работы с любыми нейронными сетями.;
5. Процессор Cerebras оказывается в сотни или даже тысячи раз эффективнее для ИИ и машинного обучения.

Images are not static!



Automatic alignment and pose estimation



受入

88-2-75

高工研圖書室

Preprint ЕФИ-992(42)-87

ԵՐԵՎԱՆԻ ՖԻԶԻԿԱՅԻ ԻՆՏԻՏՈՒՏ
ЕРЕВАНСКИЙ ФИЗИЧЕСКИЙ ИНСТИТУТ
YEREVAN PHYSICS INSTITUTE



A.A.CHILINGARYAN,N.O.KHUDONYAN,

D.B.SAAKYAN,G.Z.ZAZYAN

RECOGNITION OF CORRELATED PATTERNS WITH
SPIN GLASS-LIKE MODELS

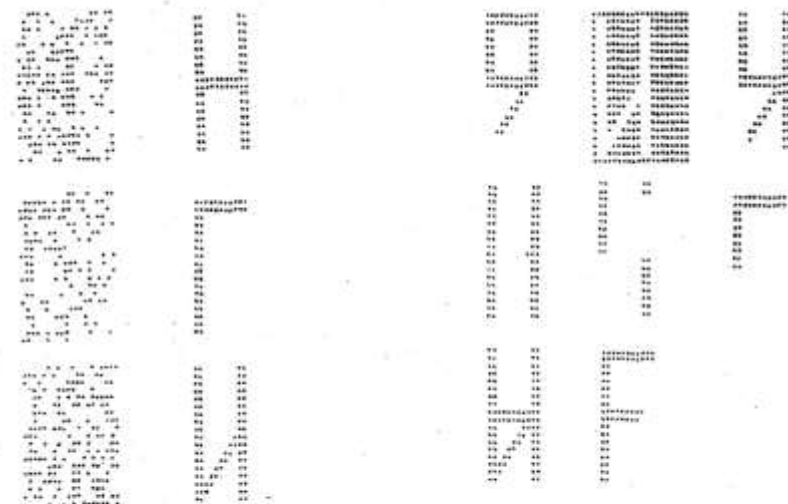


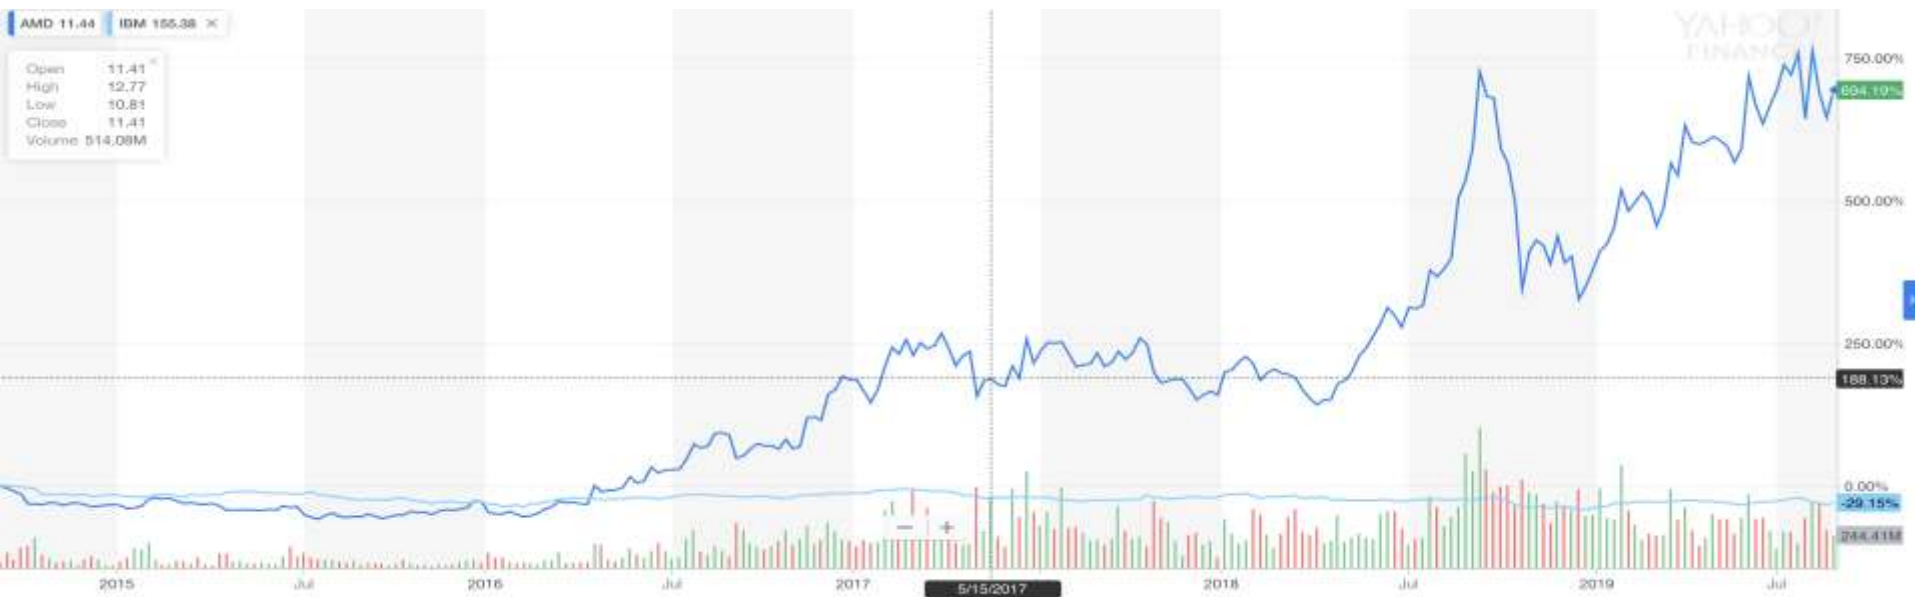
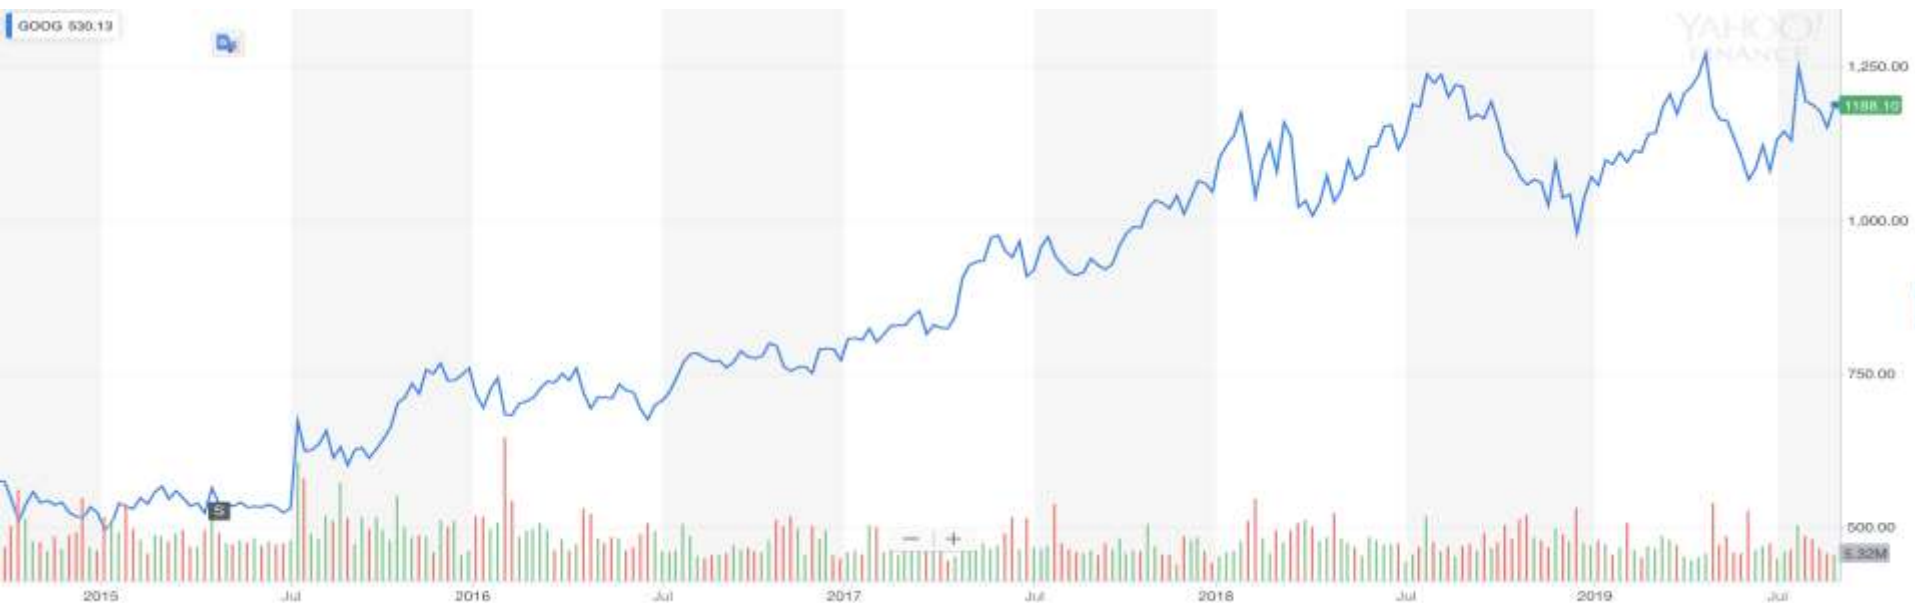
Fig-2

Fig-1

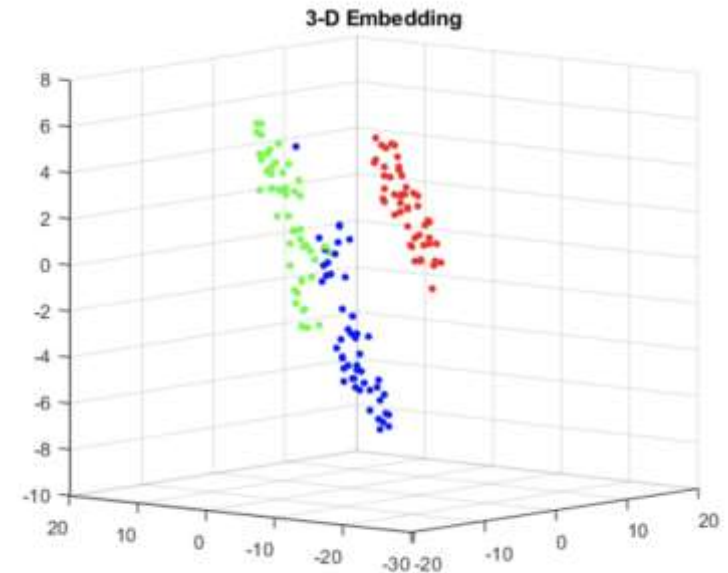
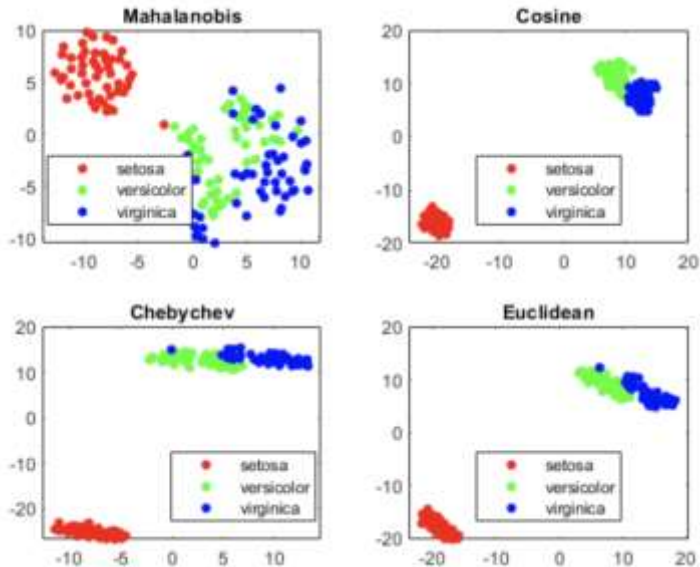
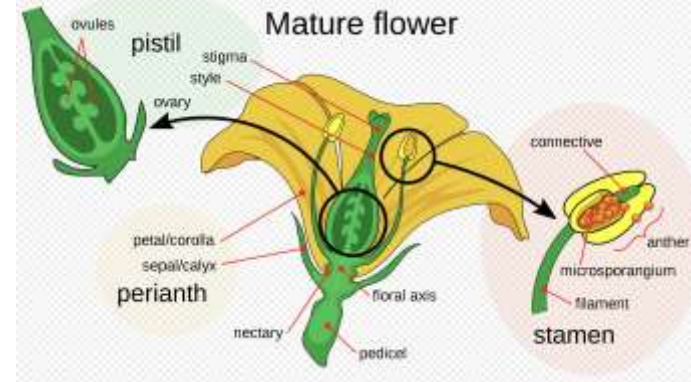
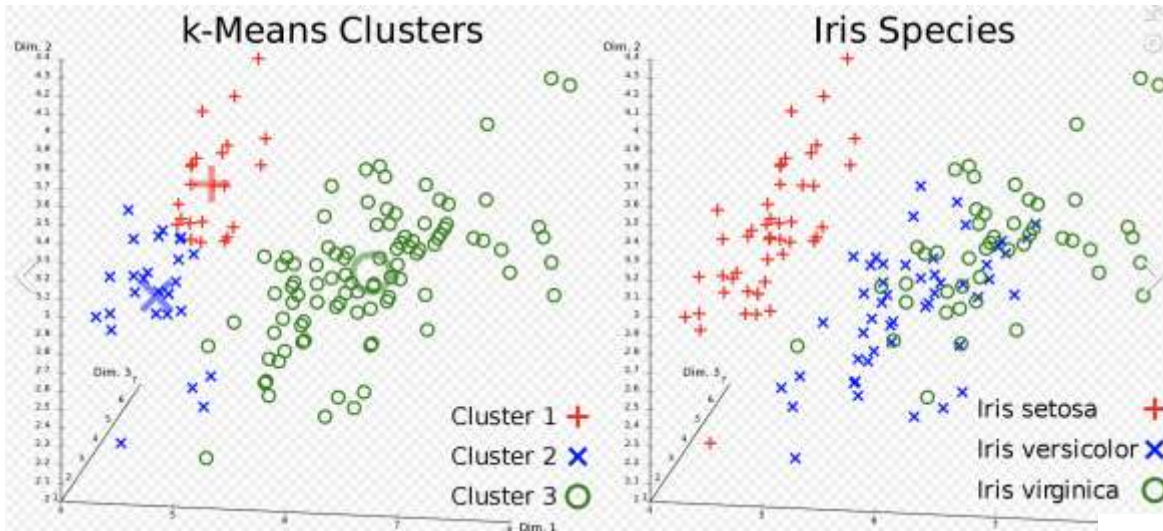


ЦНИИатоминформ
ЕРЕВАН — 1987

Stock Markets: forecasting; regression; optimal strategy: Stocks, Commodities Tumble as China Strikes Back



Fisher IRIS flower dataset (1936)



<https://archive.ics.uci.edu/ml/datasets/iris>

UC Irvine Machine Learning Repository

<https://archive.ics.uci.edu/ml/index.php>



[About](#) [Citation Policy](#) [Donate a Data Set](#) [Contact](#)

Repository Web

[View ALL Data Sets](#)

Browse Through: **481 Data Sets**

[Table View](#) [List View](#)

Default Task	Name	Data Types	Default Task	Attribute Types	# Instances	# Attributes	Year
Classification (356) Regression (103) Clustering (88) Other (55)	Abalone	Multivariate	Classification	Categorical, Integer, Real	4177	8	1995
Attribute Type Categorical (38) Numerical (318) Mixed (55)	Adult	Multivariate	Classification	Categorical, Integer	48842	14	1996
Data Type Multivariate (367) Univariate (24) Sequential (49) Time-Series (94) Text (55) Domain-Theory (23) Other (21)	Annealing	Multivariate	Classification	Categorical, Integer, Real	798	38	
Area Life Sciences (109) Physical Sciences (49) CS / Engineering (177) Social Sciences (26) Business (31) Game (10) Other (74)	Anonymous Microsoft Web Data		Recommender-Systems	Categorical	37711	294	1998
# Attributes Less than 10 (117) 10 to 100 (217) Greater than 100 (85)	Arrhythmia	Multivariate	Classification	Categorical, Integer, Real	452	279	1998
# Instances Less than 100 (27) 100 to 1000 (166) Greater than 1000 (254)	Artificial Characters	Multivariate	Classification	Categorical, Integer, Real	6000	7	1992
Format Type Matrix (320)	Audiology (Original)	Multivariate	Classification	Categorical	226		1987
	Audiology (Standardized)	Multivariate	Classification	Categorical	226	69	1992
	Auto MPG	Multivariate	Regression	Categorical, Real	398	8	1993

CRD Machine Learning resources



Home Space Education Machine Learning lectures



Machine Learning lectures

Machine Learning lectures

1. Machine Learning: Bayesian and Neural Network statistical models

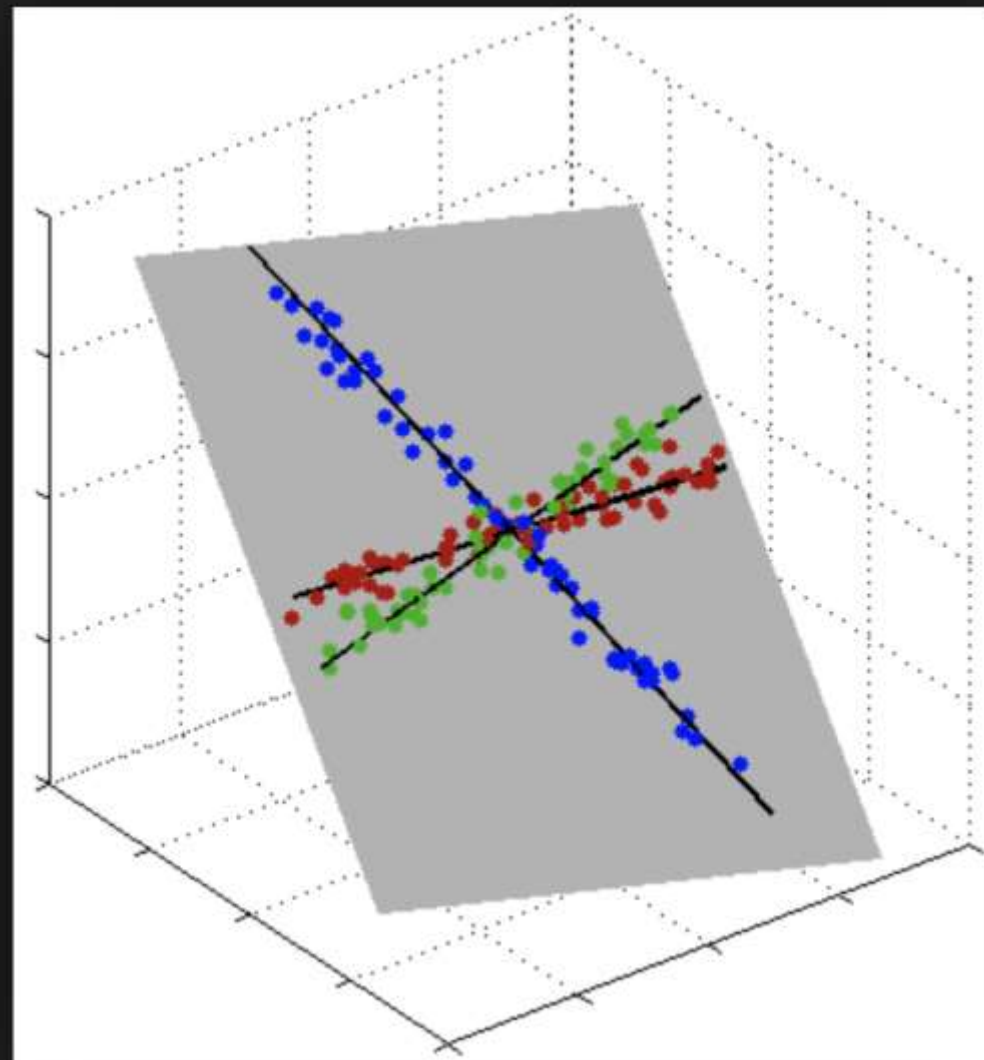
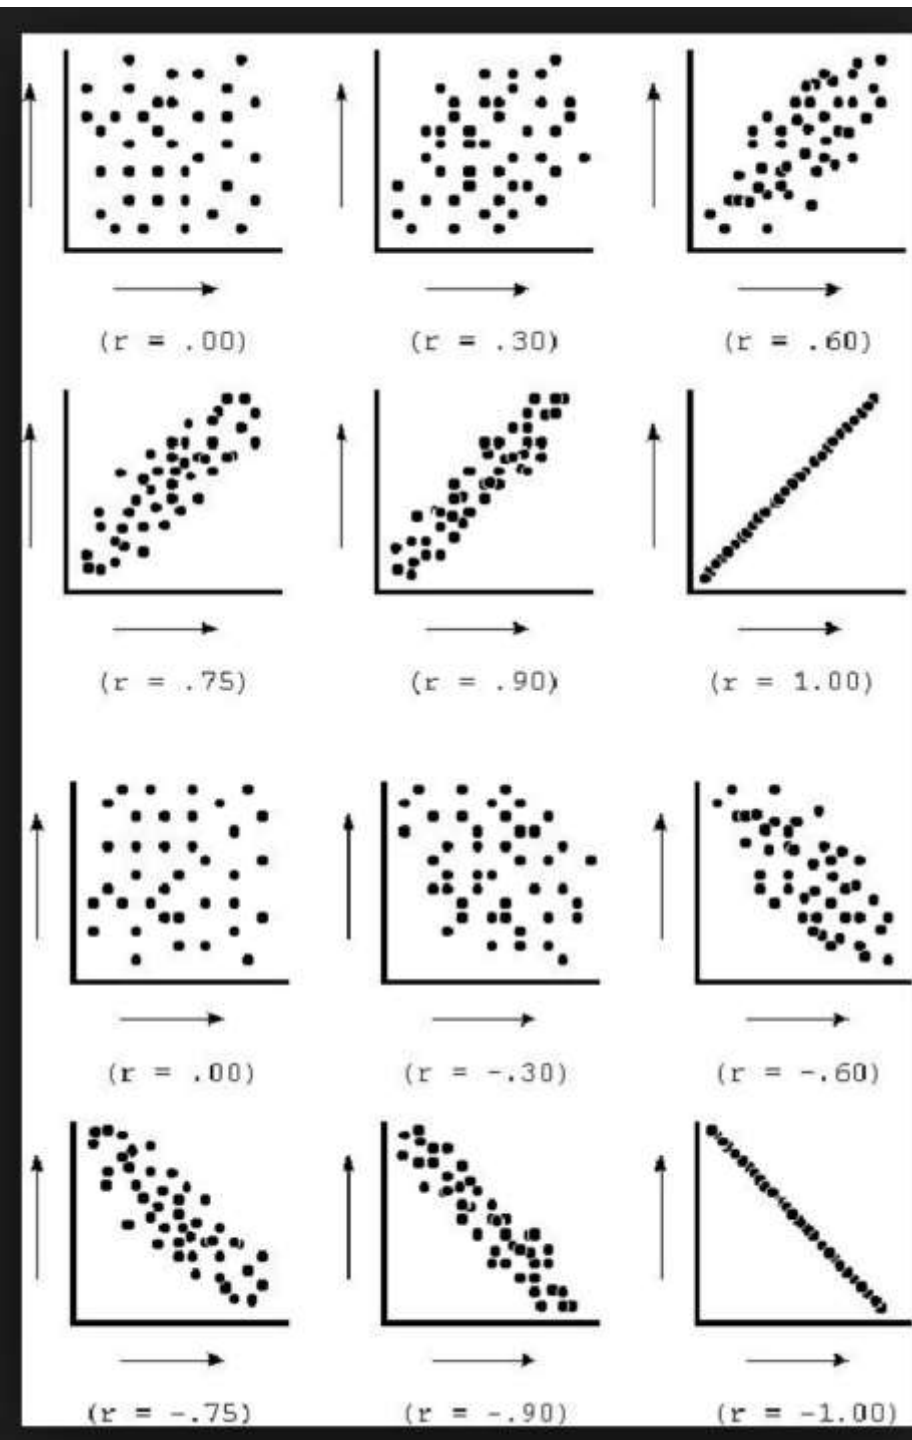
Author: Ashot Chilingarian

2. ANI Applied Nonparametric Inference Reference Manual Version 19.1

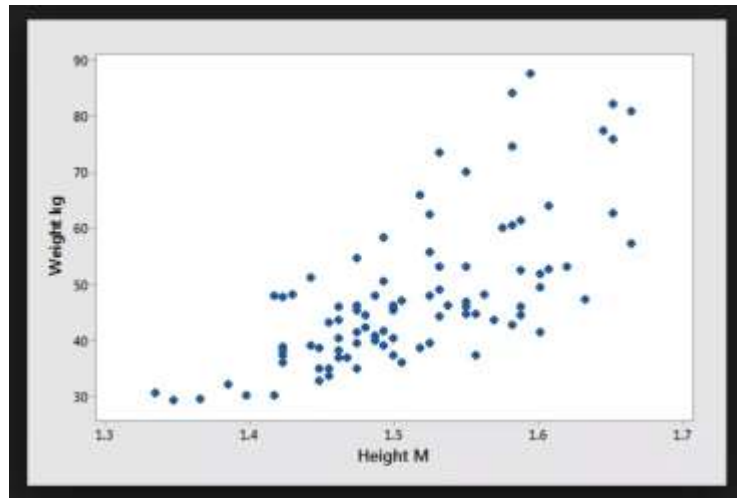
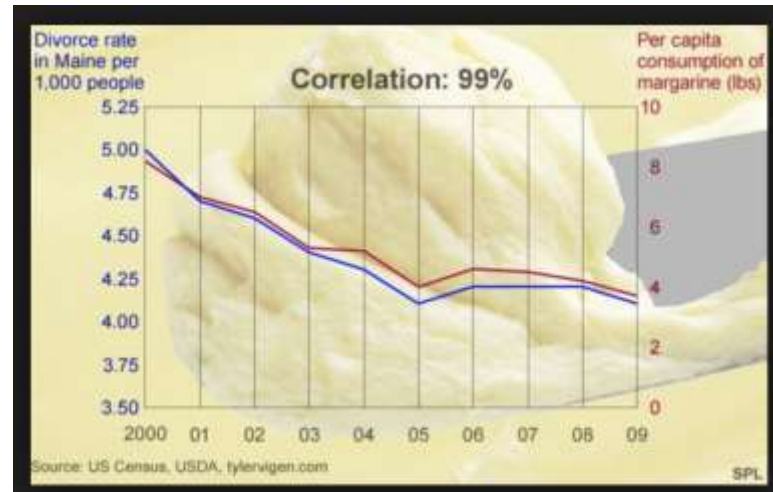
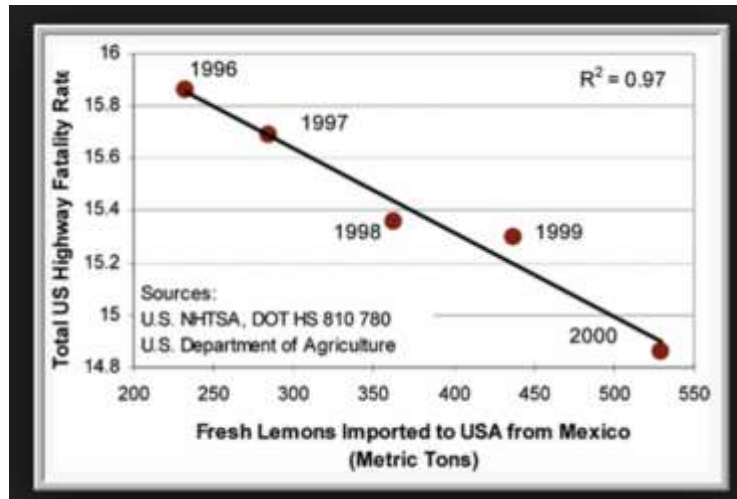
Author: Ashot Chilingarian

Correlation

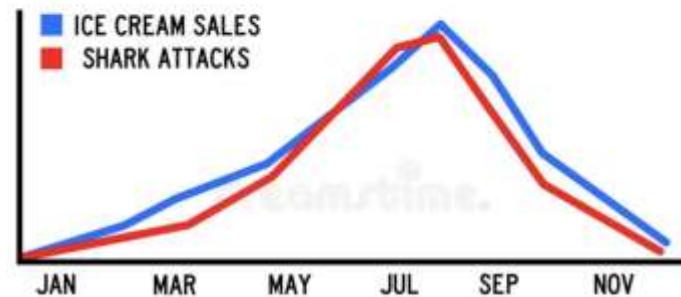
$$r = \frac{n(\sum xy) - (\sum x)(\sum y)}{\sqrt{[n\sum x^2 - (\sum x)^2][n\sum y^2 - (\sum y)^2]}}$$



“False” Correlations no causal relation

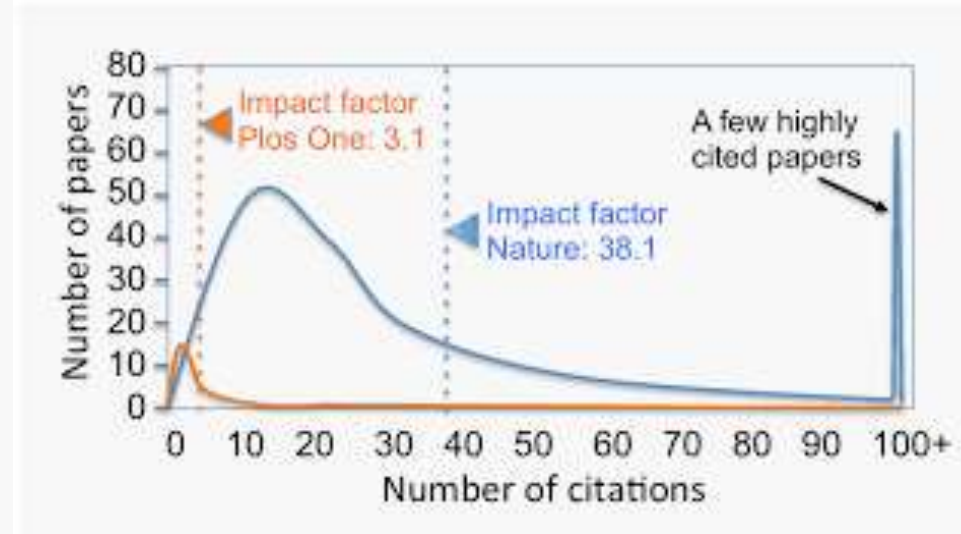
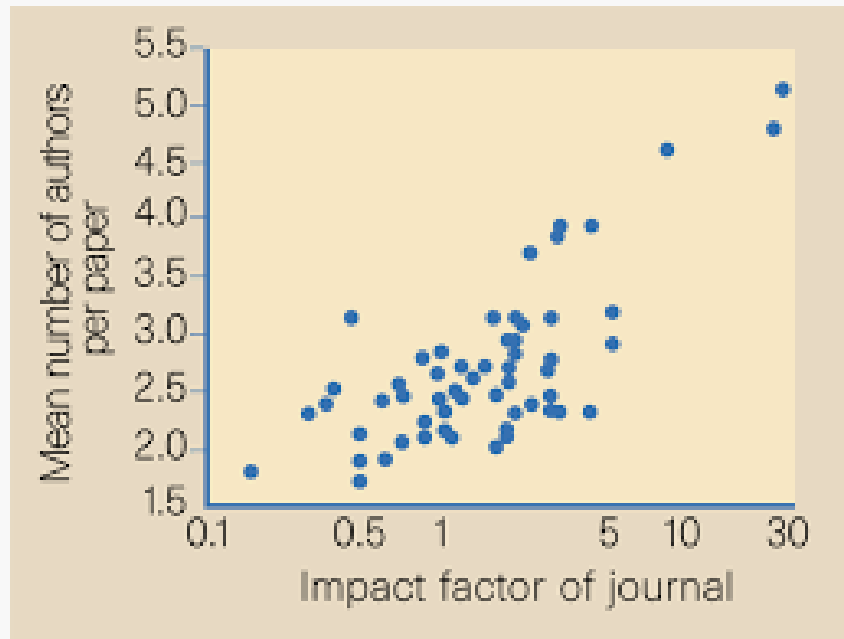


CORRELATION IS NOT CAUSATION!



Both ice cream sales and shark attacks increase when the weather is hot and sunny, but they are not caused by each other (they are caused by good weather, with lots of people at the beach, both eating ice cream and having a swim in the sea)

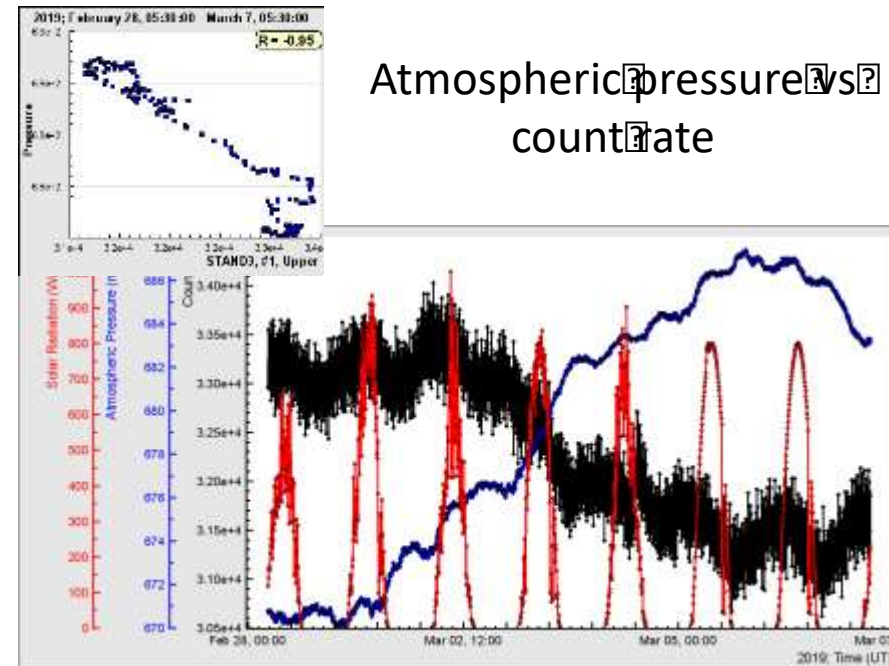
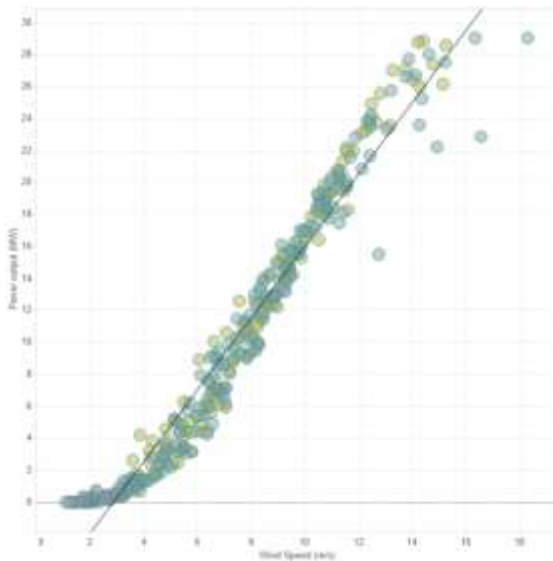
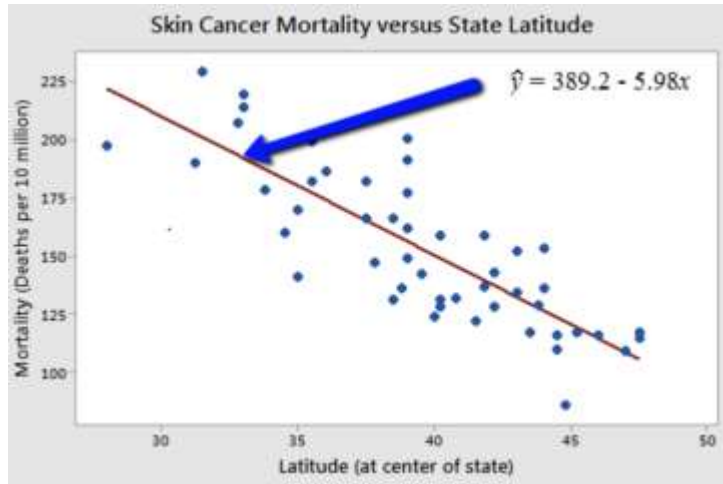
“Good and bad” journals; Impact factor



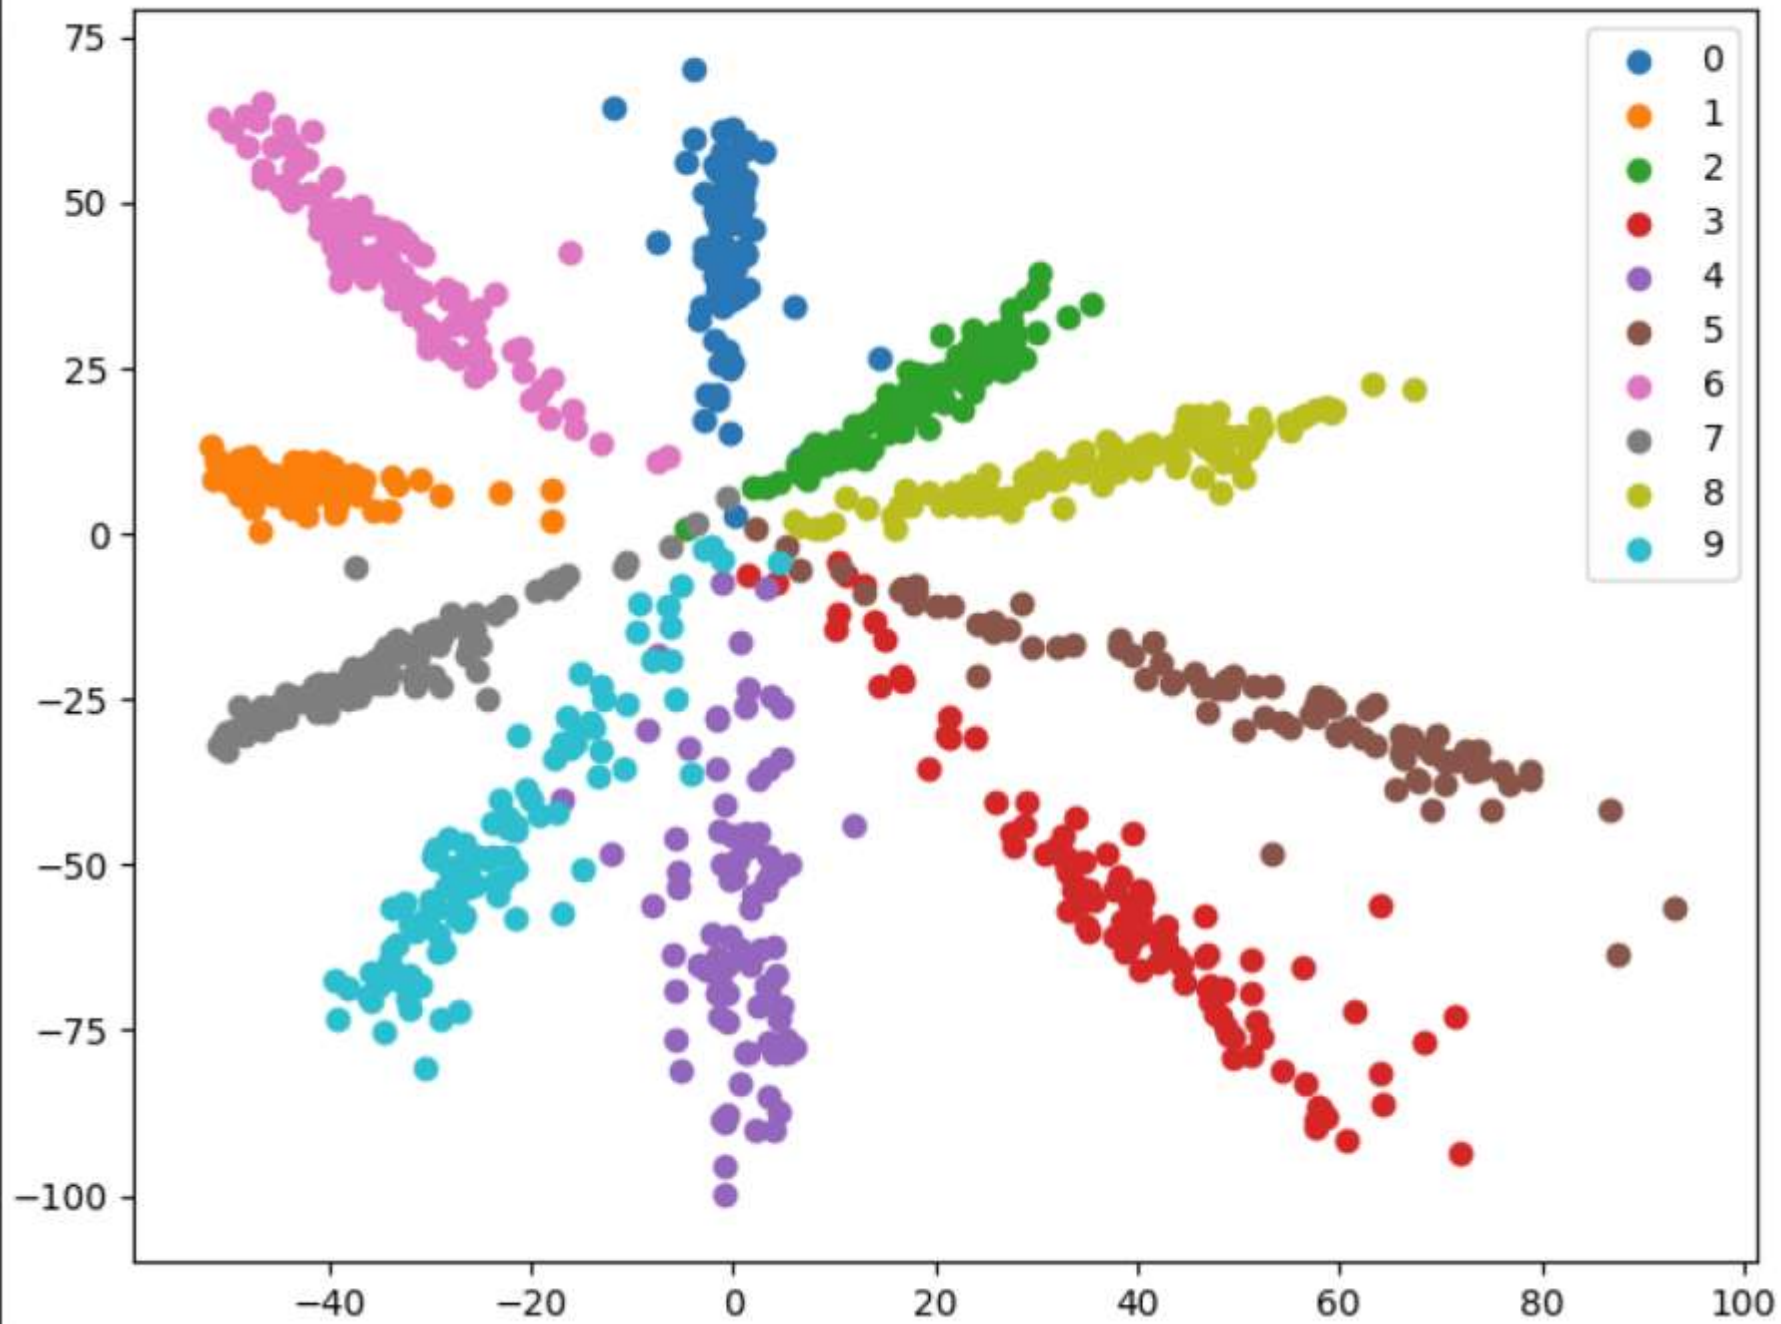
Observer make correlation: number of umbrellas – intensity of rain and get highly positive; thus we can make rain by taking umbrellas!



True correlation – causal relations

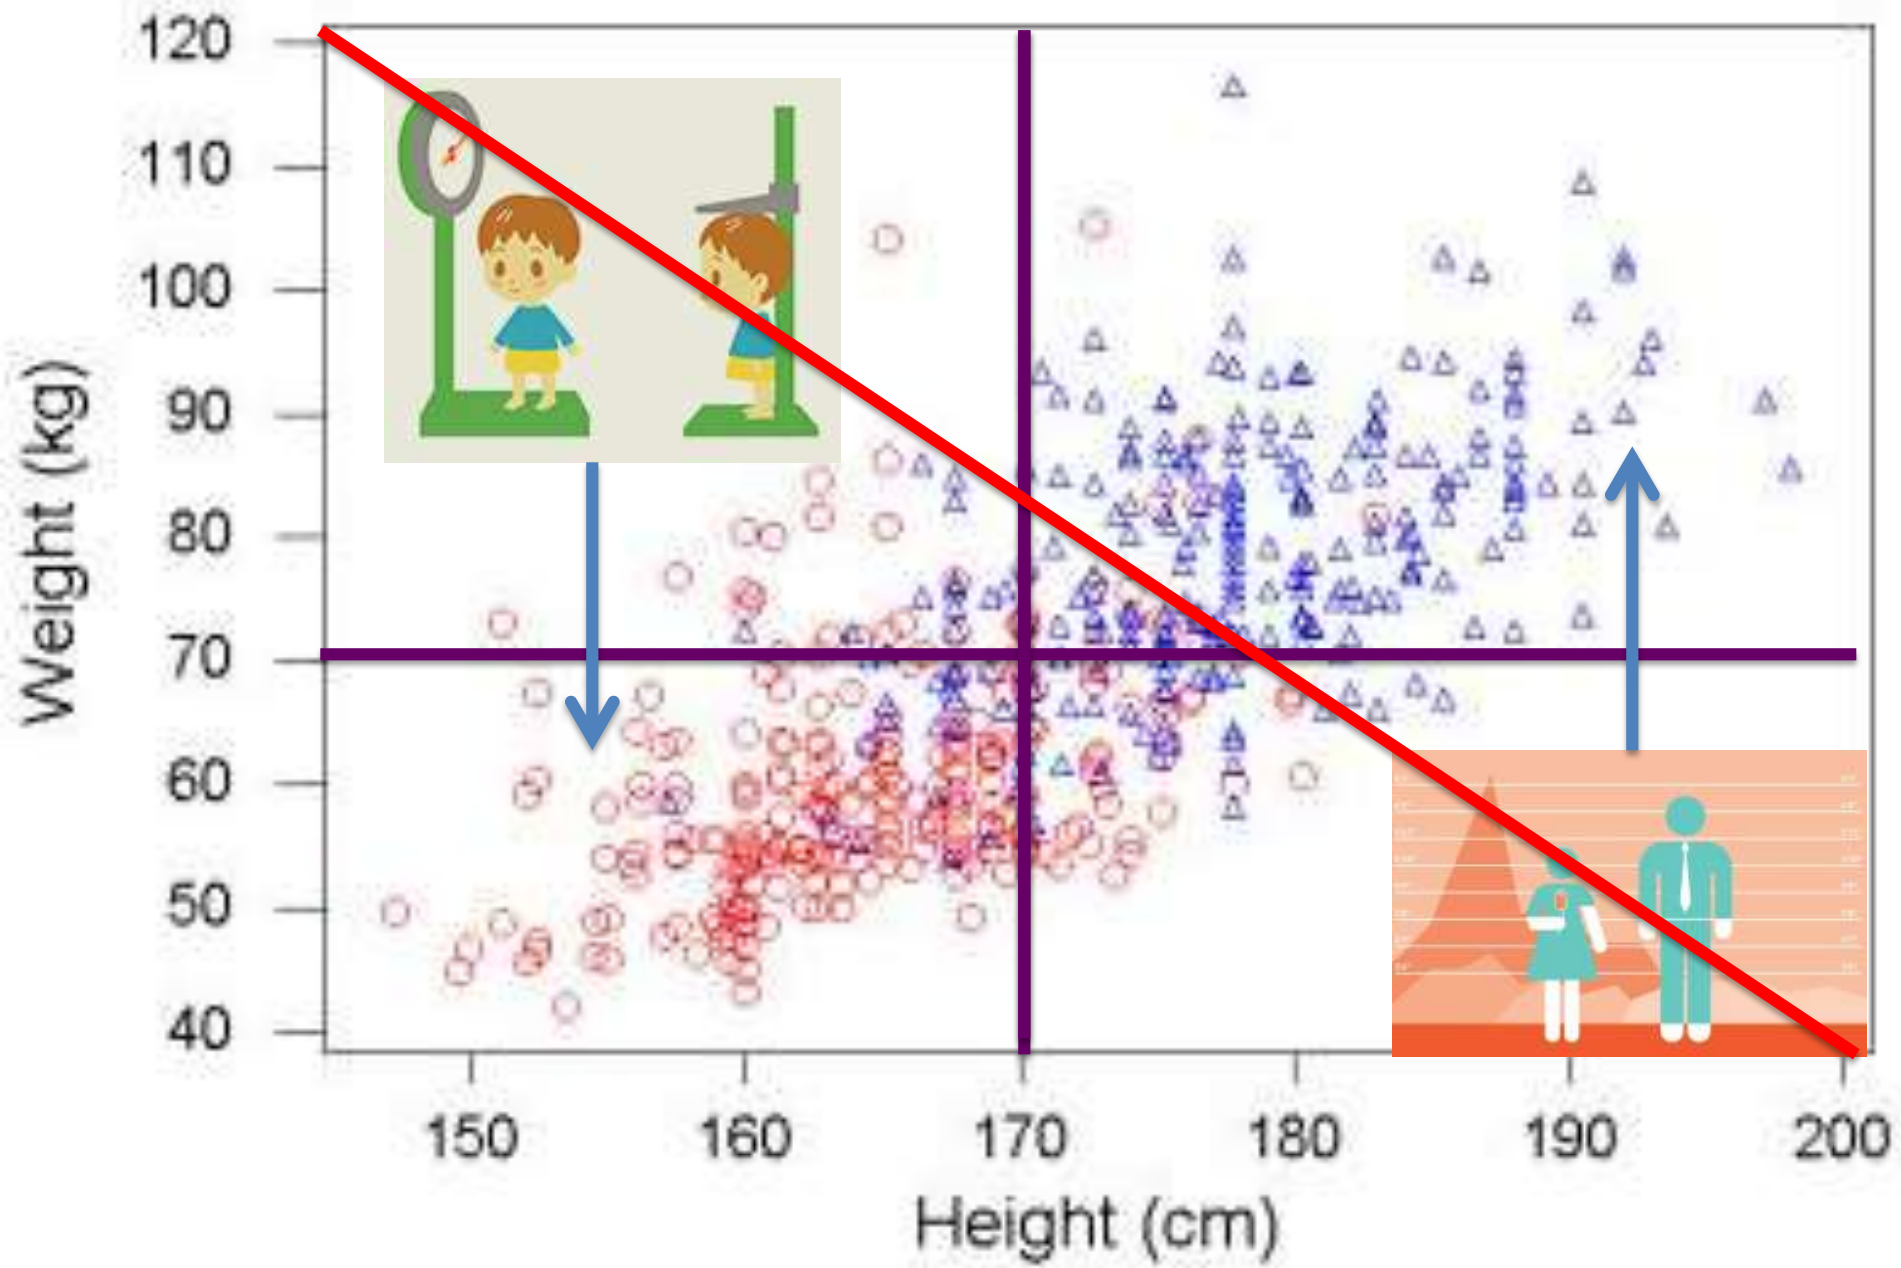


Atmospheric pressure vs count rate



Example: automatic selection of child and adult

1. Goal – cinema: 12+, or 16+; Speed of autopilots on the roads in presence near schools; airplane passengers;
2. Select variables: measurements of weight and height (no problem);
3. Domain – direct product of x and y spaces $R^1 \times R^1$;
4. How to deal with random variables? The mean and variance: Gaussian distribution! 2 main parameters!
5. 2 different variables: deviation from mean; %, or N of sigma, range.
6. Classification problem as mapping problem



Mapping feature space to decision space!

1. **$f(x, y) = x+y$** : What will be if we add kilograms and meters?
2. **Percent of mean value:** Mean weight 70 kg, mean height – 170 cm;
3. 100 kg $(100-60)/60 \sim 66.7\%$; 30 kg $(30-60)/60=-50\%$;
4. Now we can add percent! $F(x+y)=66.7\%+ -50\% = 17.7\%$
5. Mapping of 2 dimensional feature space – to one dimensional decision space!
6. $f(x,y) = 1$, if $x+y < 50\%$; $f(x,y)=2$, if $x+y > 50\%$
7. But why 50? Maybe 45 will be better?
8. Training with teacher to find best mapping function!

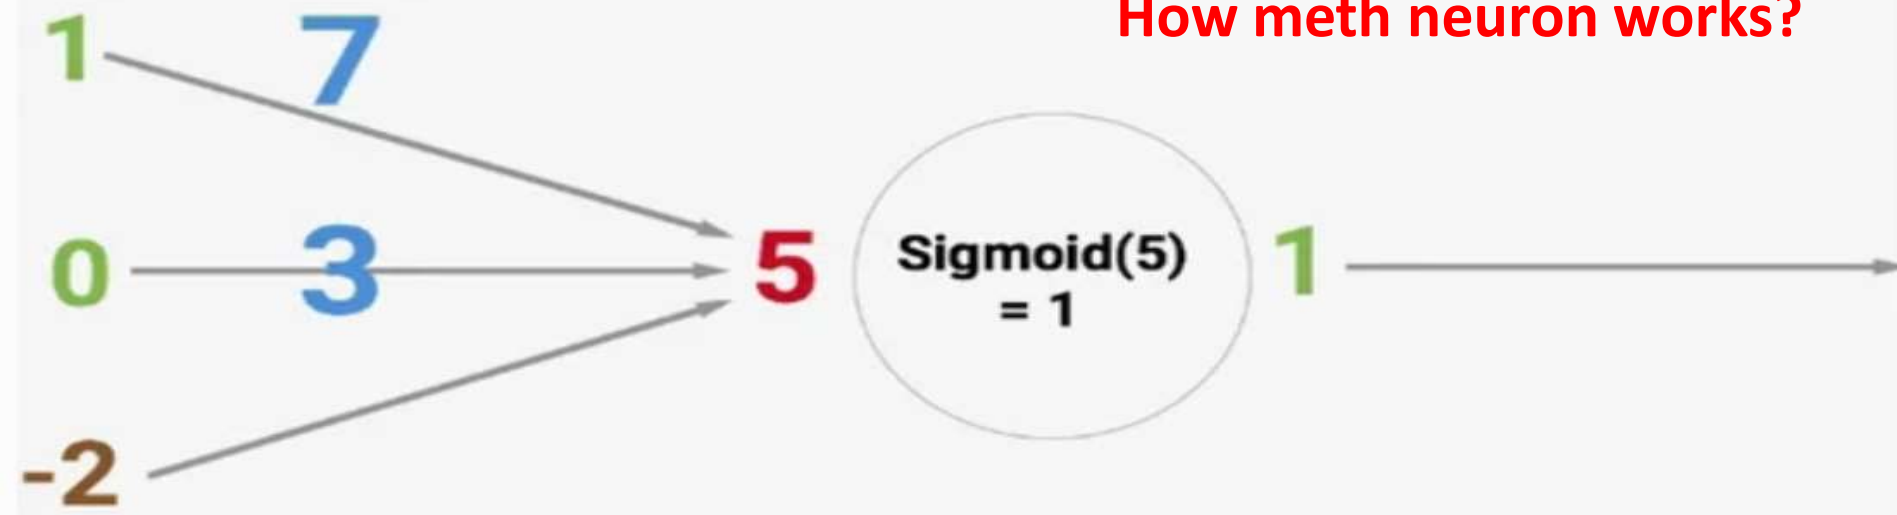
Metrics to Evaluate your Machine Learning Algorithm (we need training sample TS – measurements with known classification)

$$\text{Accuracy} = \frac{\text{Number of Correct predictions}}{\text{Total number of predictions made}}$$

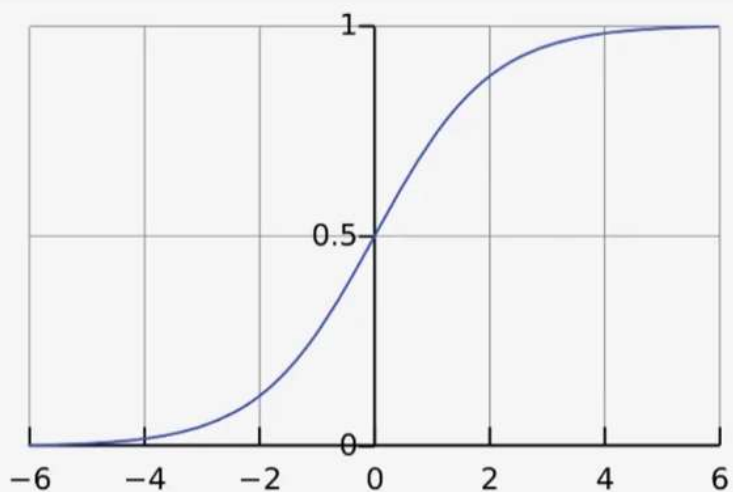
	Predicted: NO	Predicted: YES
n=165		
Actual: NO	50	10
Actual: YES	5	100

$$\text{MeanAbsoluteError} = \frac{1}{N} \sum_{j=1}^N |y_j - \hat{y}_j| \quad \text{MeanSquaredError} = \frac{1}{N} \sum_{j=1}^N (y_j - \hat{y}_j)^2$$

How meth neuron works?



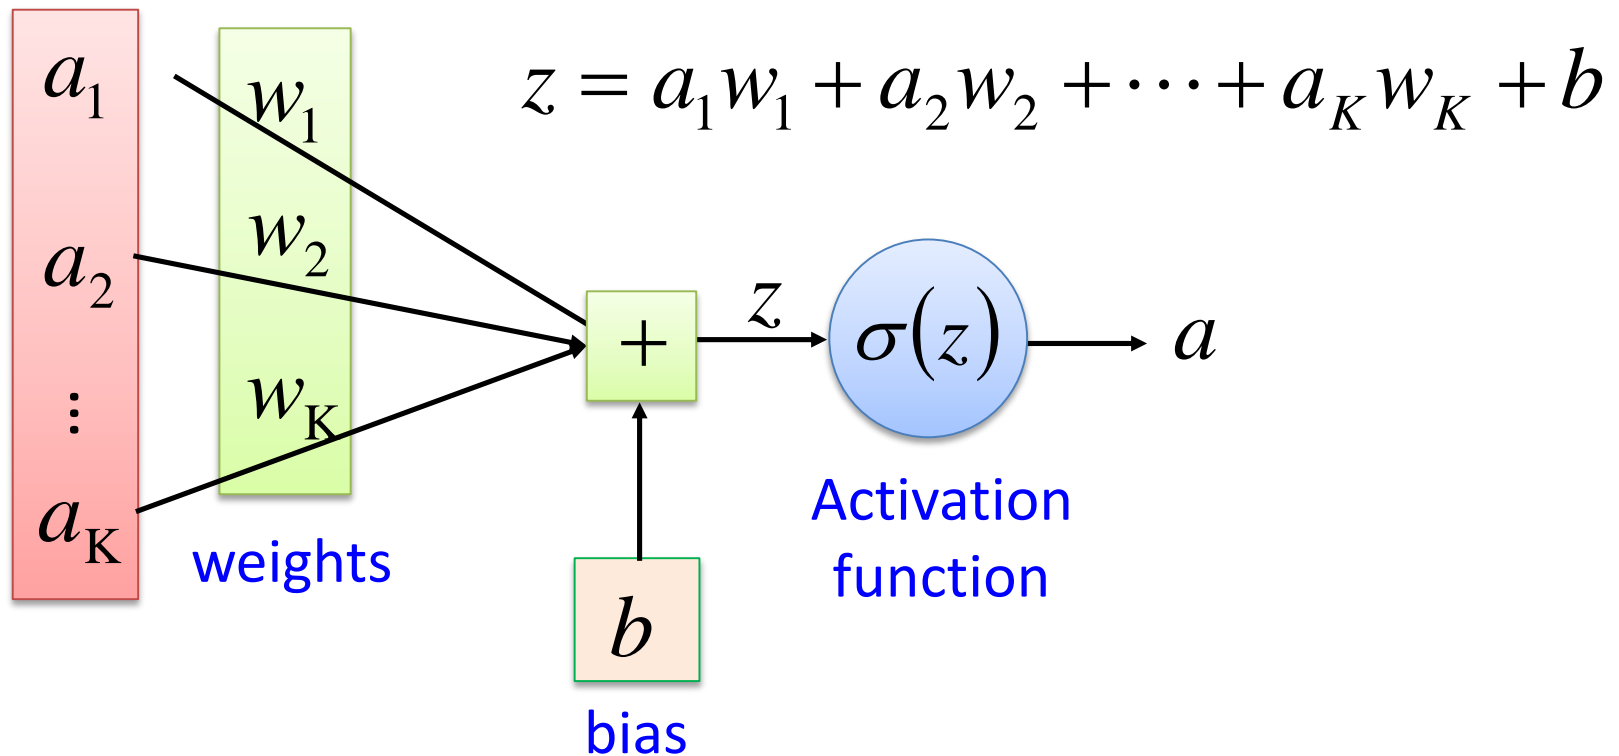
$$1 * 7 + 0 * 3 - 2 = 5$$



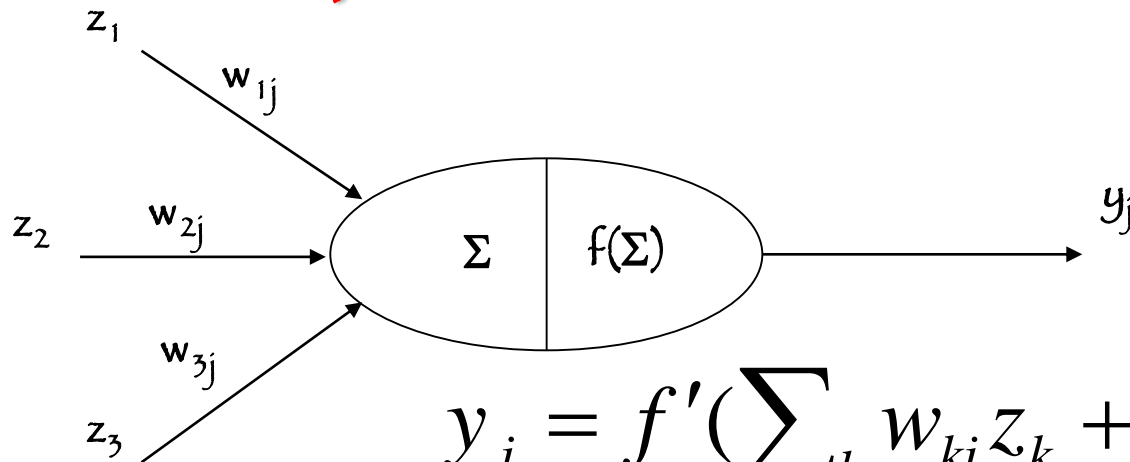
<https://zen.yandex.ru/media/id/5bbcbc1ba5bd5400a990e7d9/izuchaem-neironnye-seti-kak-sozdat-neiroset-za-4shaga-5cda8a1a5631d800b3136f0f>

Element of Neural Network

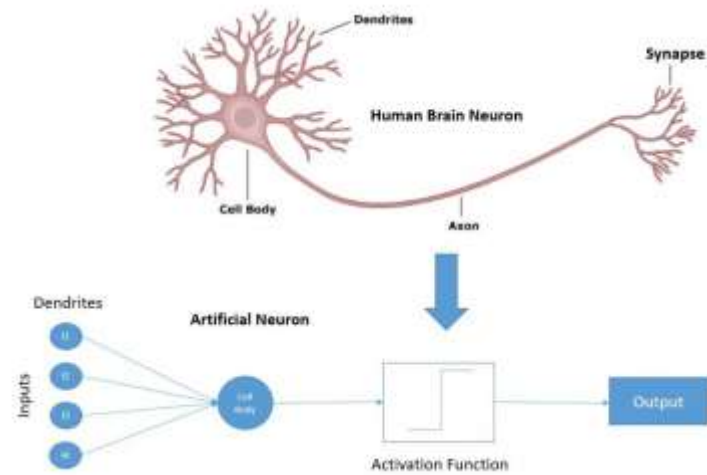
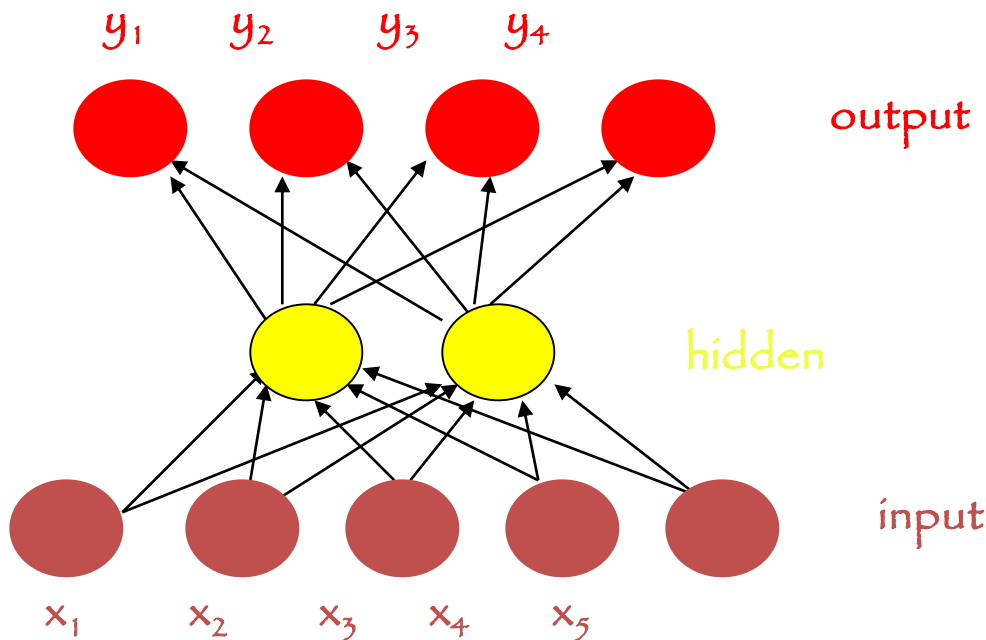
Neuron $f: R^K \rightarrow R$



The artificial neuron: how to train?



$$y_j = f'(\sum_k w_{kj} z_k + w_{0j}) =$$
$$= f'(\sum_k w_{kj} (f(\sum_i w_{ik} x_i + w_{0k}))) + w_{0j}$$



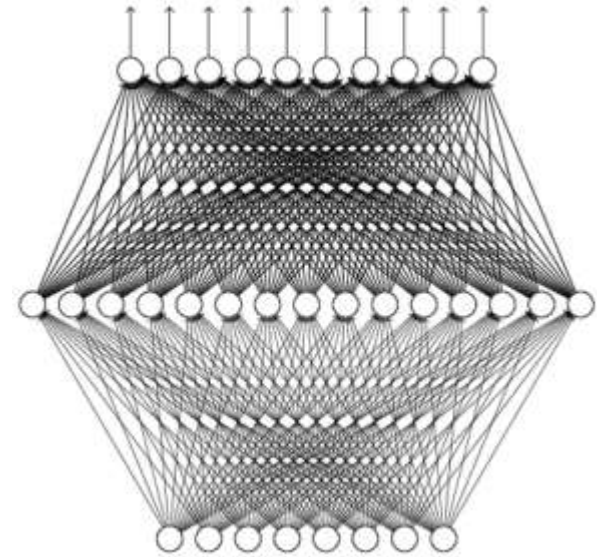
Universality Theorem

Any continuous function f

$$f : R^N \rightarrow R^M$$

Can be realized by a network with one hidden layer

(given **enough** hidden neurons)! So, what for we need deep NN with many-many layers?



Reference for the reason:
<http://neuralnetworksanddeeplearning.com/chap4.html>

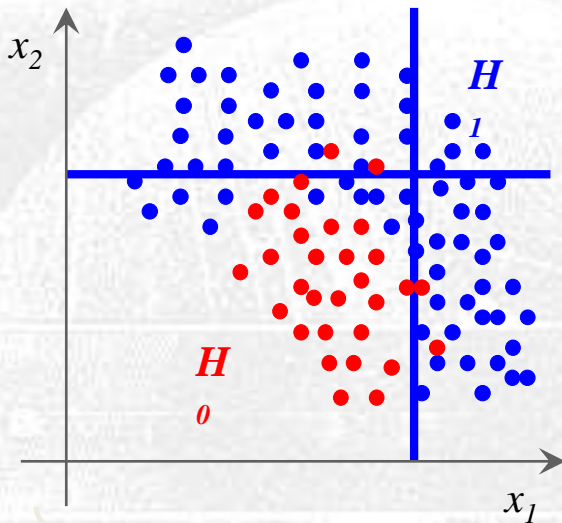
Why “Deep” neural network not “Fat” neural network?

Classification of primary hadron to light and heavy nuclei

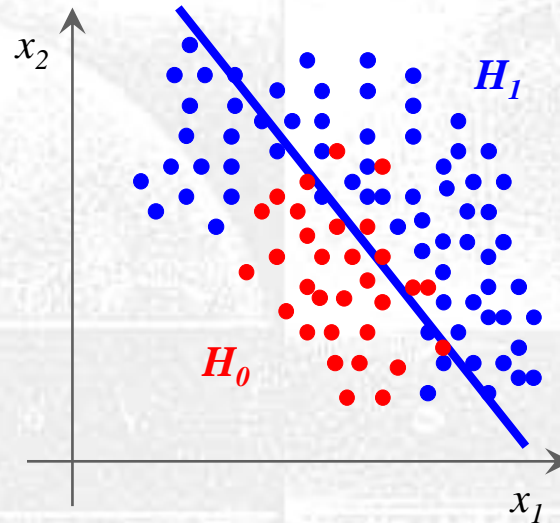
Suppose data sample with two types of events: Protons and Iron nuclei obtained from the simulation – solving direct problem of CR!

- We have found discriminating input parameters N_e and N_{mu}
- What decision boundary should we use to select Iron nuclei ?

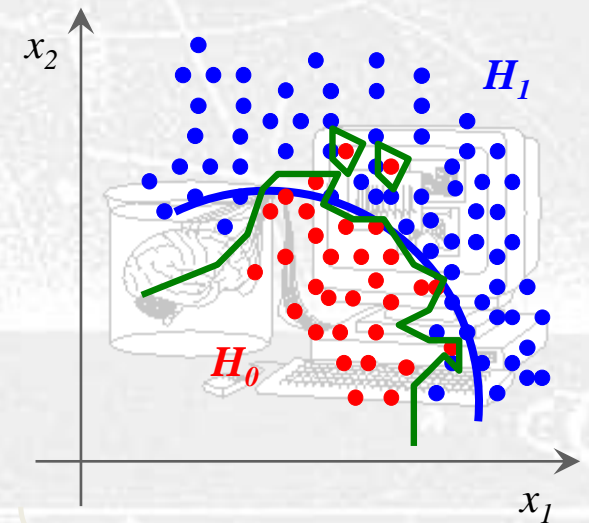
Rectangular cuts?



A linear boundary?

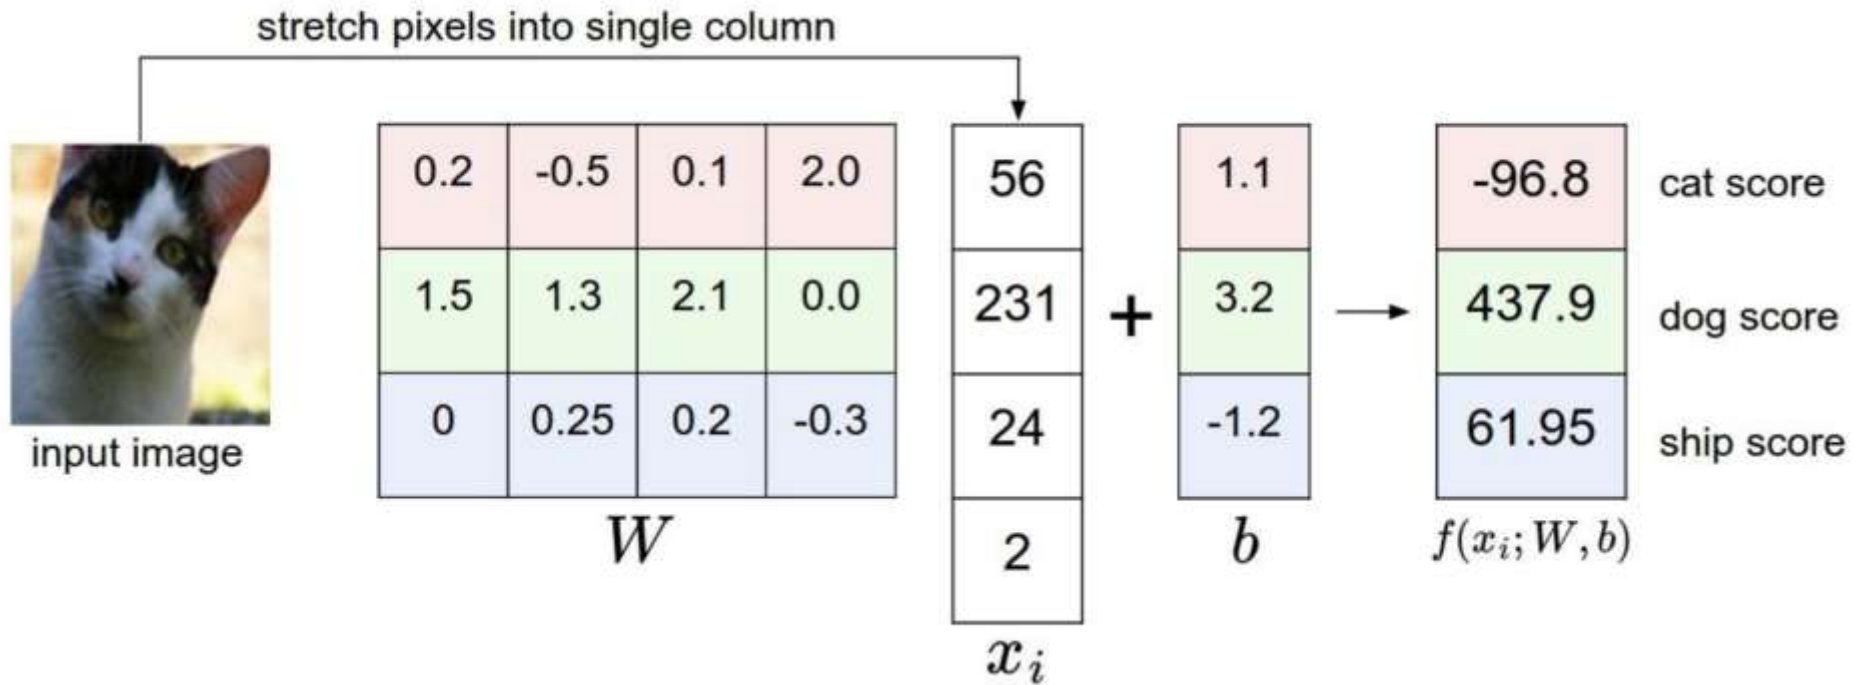


A nonlinear one?

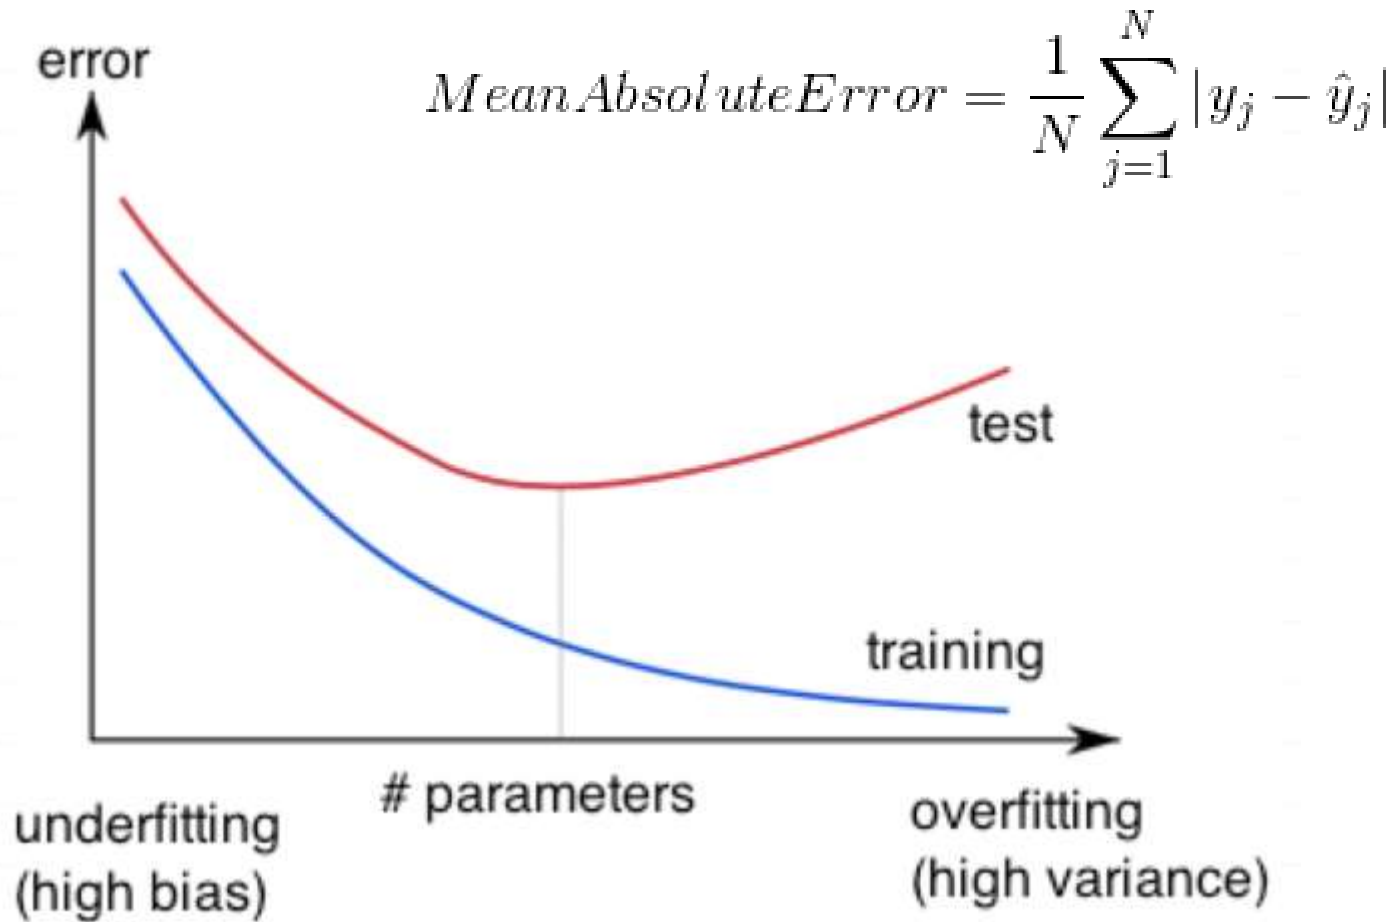


- How can we decide this in an optimal way ? → Let artificial neural network do it!
- We need training samples – training with teacher – simulations, direct CR problem

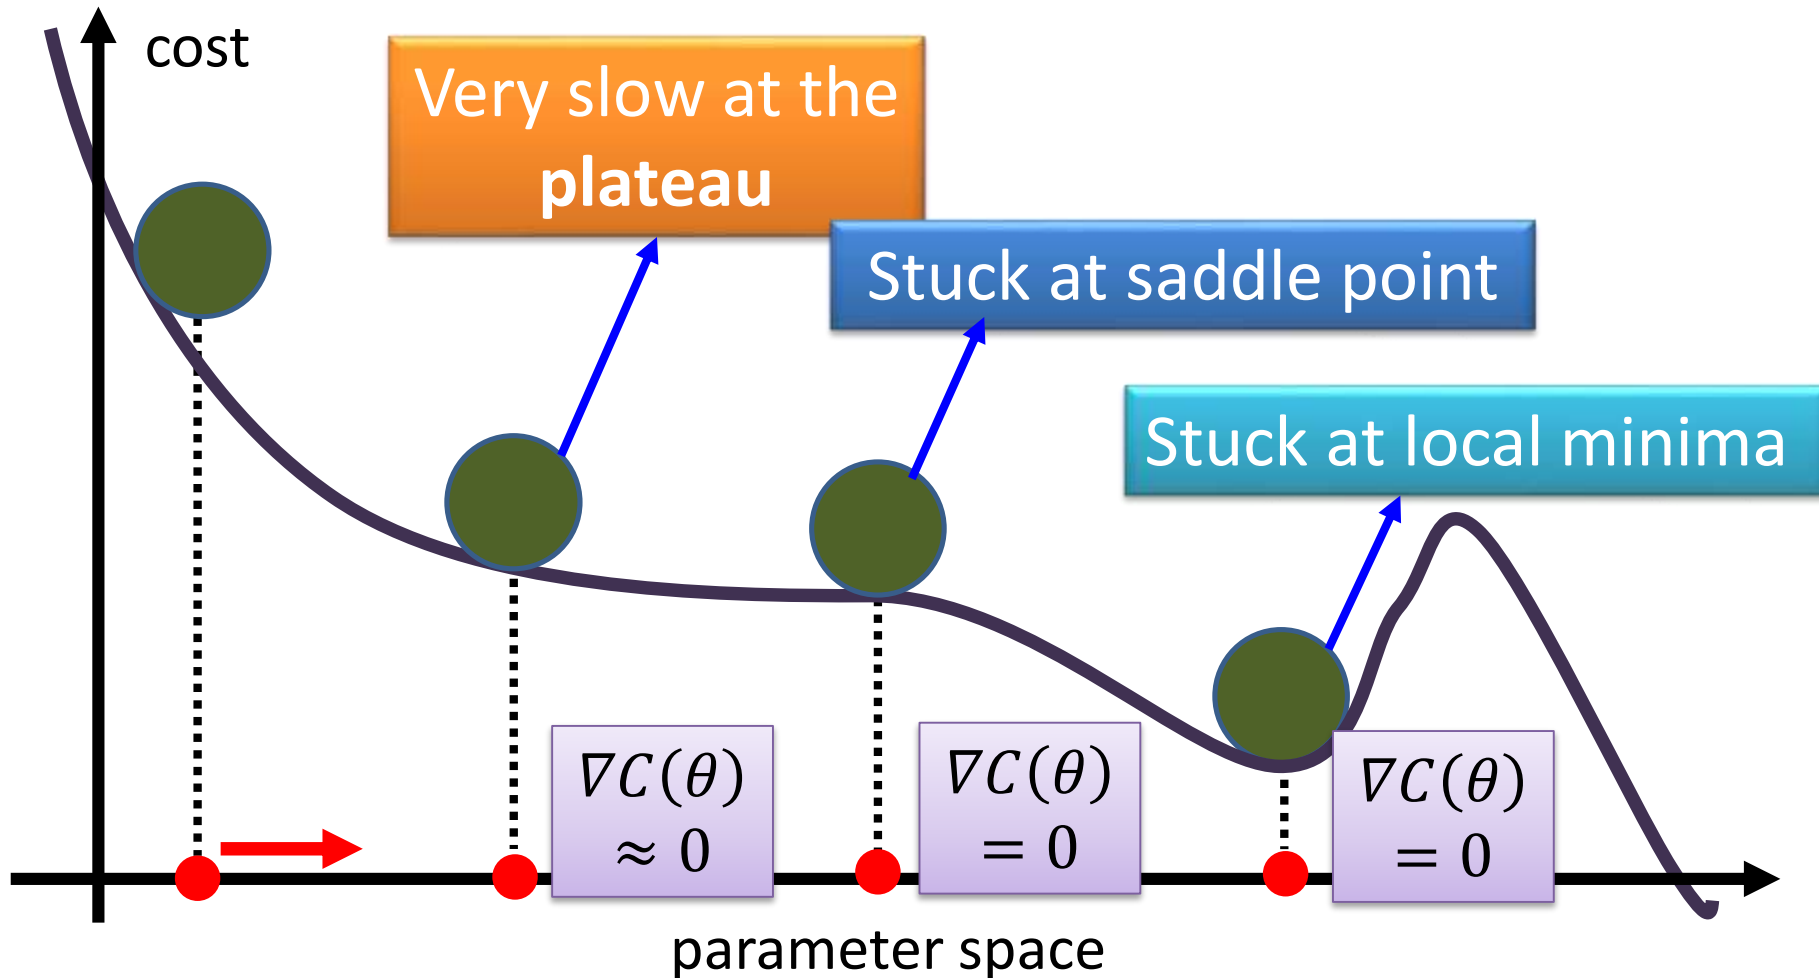
Recognizing cat: multiple feature $N \times N$ pixels



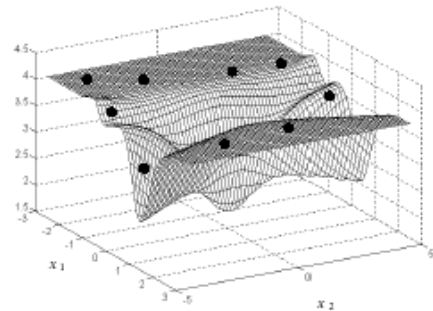
Overtraining and generalization



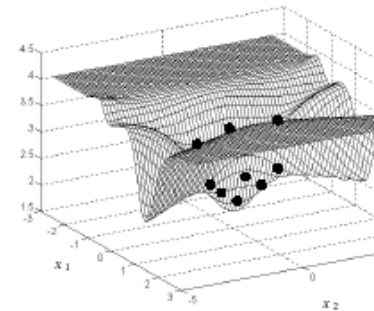
Local and global minimum



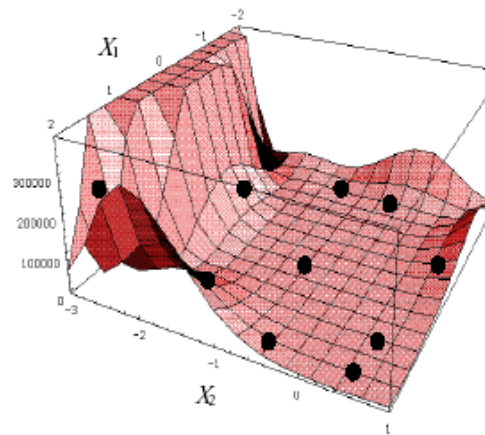
Searching of the Extremum



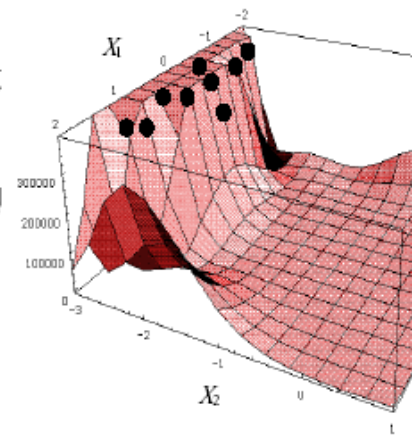
minimisation problem: $t = 1$



$t = 10$

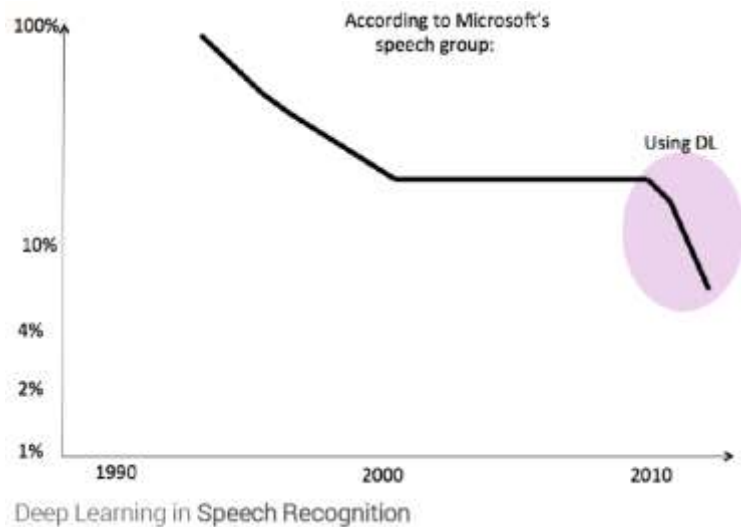
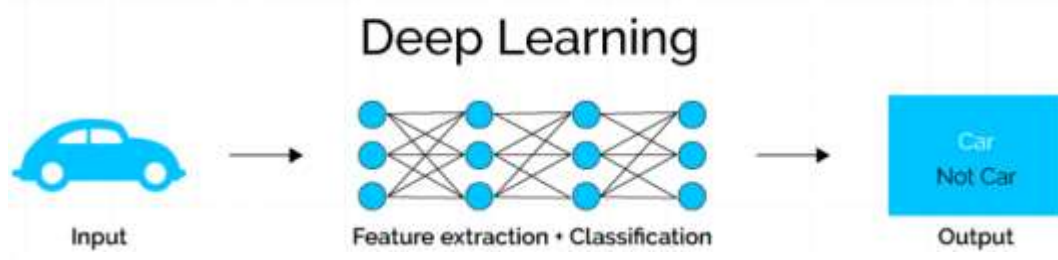
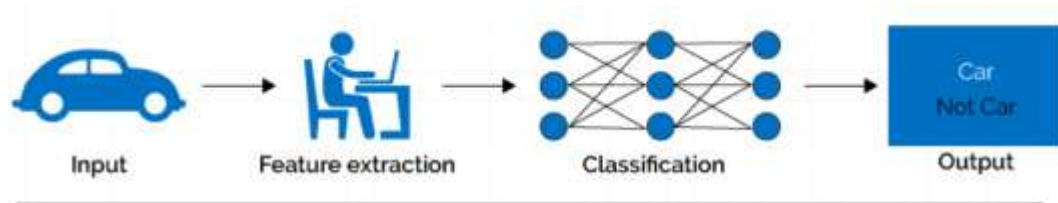
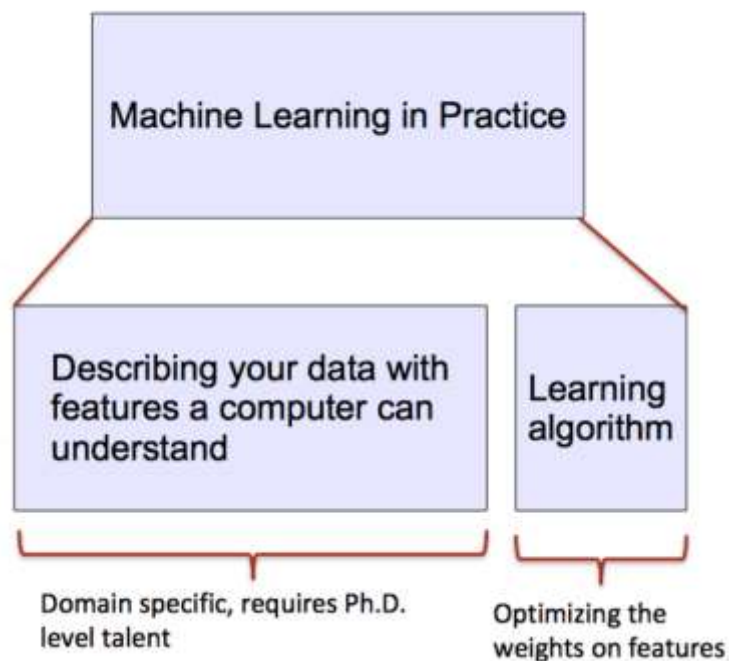


maximisation problem: $t = 1$

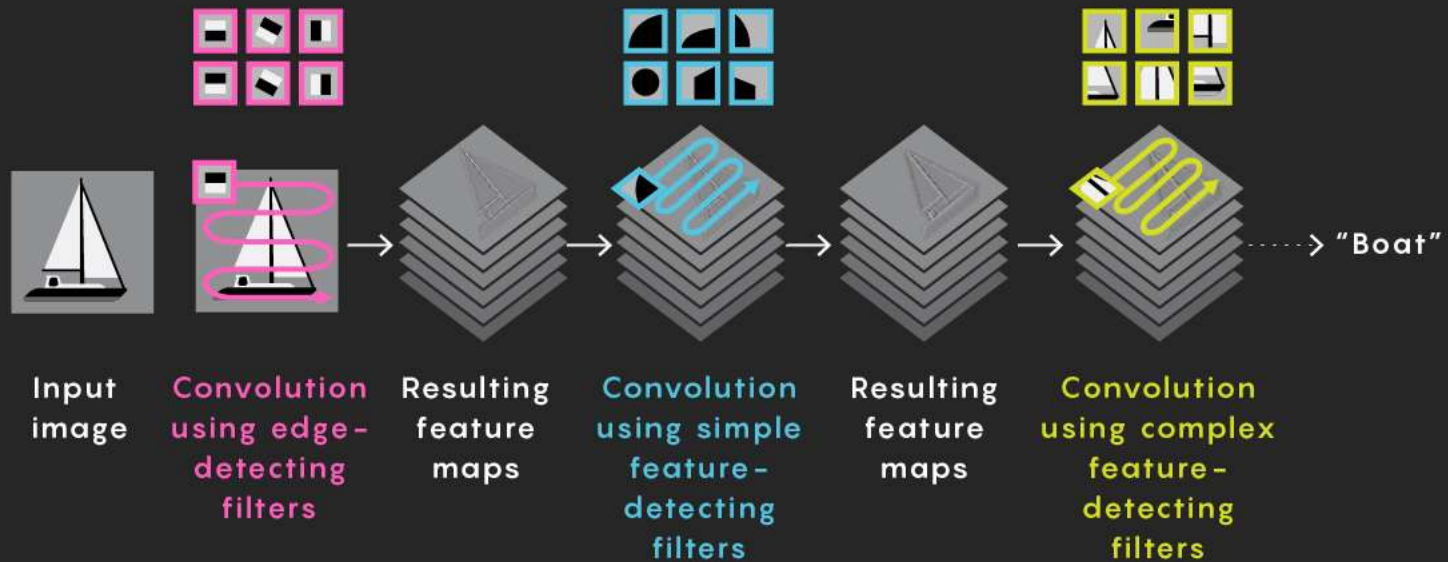


$t = 1000$

Deep learning (with and without teacher)



How Convolutional Neural Networks See



① Feature-detecting filters slide across an input image, and the degree of match between each filter and each position in the image is logged, producing a set of feature maps.

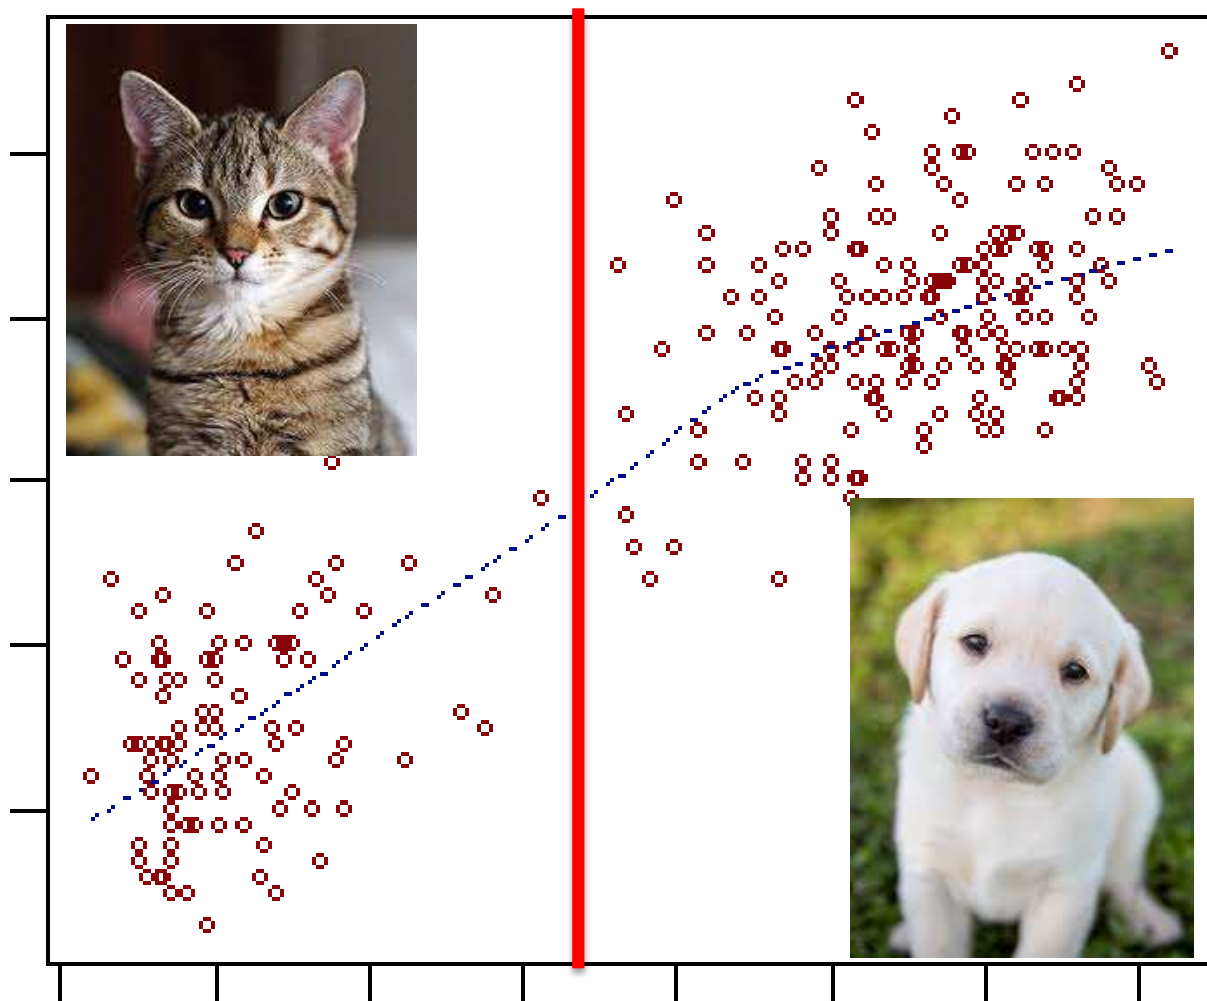
② After some processing, the feature maps are convolved again, using filters that detect increasingly high-level features.

③ Eventually, the network learns to recognize and correctly classify input images.

ML and Physics

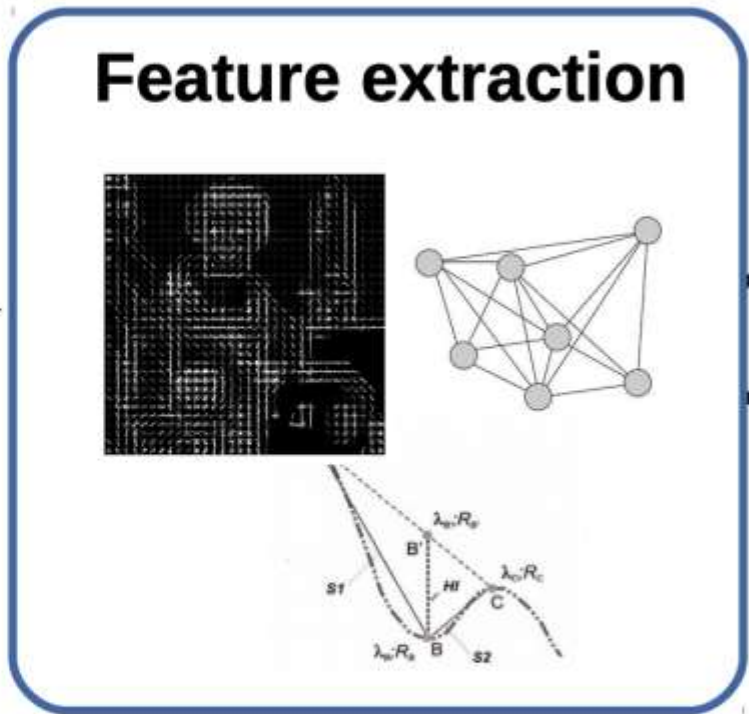
- Глубокое обучение учится очень медленно». Это не создаёт особых проблем, если вы обучаете СНС распознаванию котов (учитывая неиссякаемый запас фоток котиков в интернете). Но если вы обучаете СНС распознавать что-то более важное, типа раковых опухолей в снимке ткани лёгких, тогда найти достаточное количество обучающих данных – точных с медицинской точки зрения, правильно размеченных, свободных от копирайта – довольно сложно. И чем меньше примеров потребуется для обучения сети, тем лучше.
- один из способов увеличить эффективность данных – дать НС некое представление об этих данных заранее, например, что раковая опухоль лёгкого не перестаёт быть опухолью, если её изображение повернуть или зеркально отразить. Свёрточная сеть обычно должна обучаться такой информации с нуля, изучая множество примеров одной и той же закономерности, подаваемой в разных видах.
- У физики и машинного обучения есть нечто общее: обе области заняты наблюдениями и построением моделей, предсказывающих результаты последующих наблюдений; обе области строят модели не отдельных вещей (вряд ли полезно иметь одно описание для атома водорода, и второе – для такого же атома, только перевёрнутого), но общих категорий. «И физика, конечно же, достигла в этом больших успехов».
- Эквивариантность (или «ковариантность», как предпочитают физики) – это предположение, на которое физики полагались в обобщении своих моделей со времён Эйнштейна. «Это просто значит, что если вы правильно описываете какую-то физику, тогда это описание должно быть независимо от того, какие 'линейки' вы используете, или, в общем случае, какой вы наблюдатель», — «Общие законы природы должны выражаться уравнениями, работающими во всех системах координат».

Feature extraction: clustering training without teacher



Deep learning


Data



Knowledge about data and application



Knowledge about statistics

Expert

Machine learning

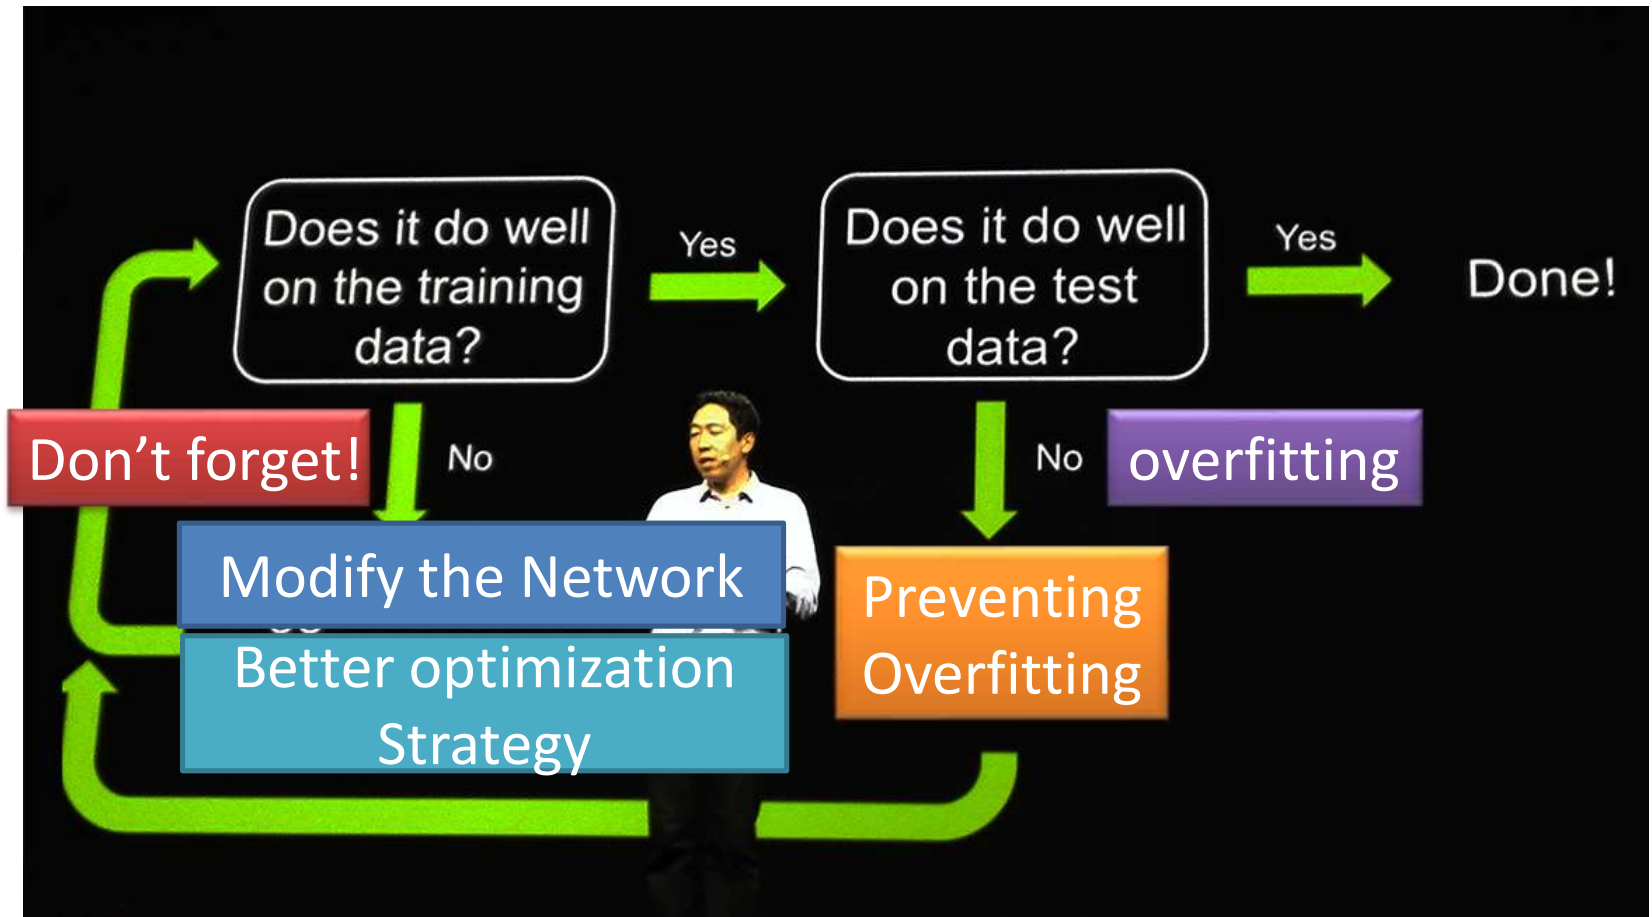
Mean Squared Error

$$J(\theta) = \frac{1}{n} \sum_{i=1}^n (y^{(i)} - \hat{y}^{(i)})^2$$

Mean Absolute Error

$$J(\theta) = \frac{1}{n} \sum_{i=1}^n |y^{(i)} - \hat{y}^{(i)}|$$

Recipe for Learning



<http://www.gizmodo.com.au/2015/04/the-basic-recipe-for-machine-learning-explained-in-a-single-powerpoint-slide/>

What tasks we want to solve in Astroparticle Physics and Genome analysis?

Inverse problems can be solved after solving direct problems!

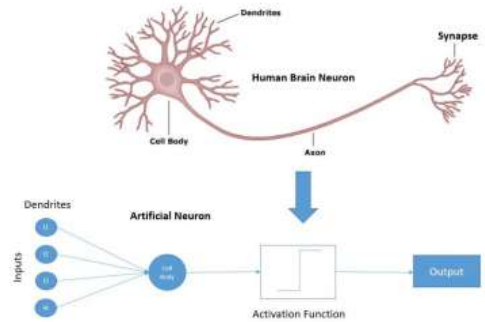
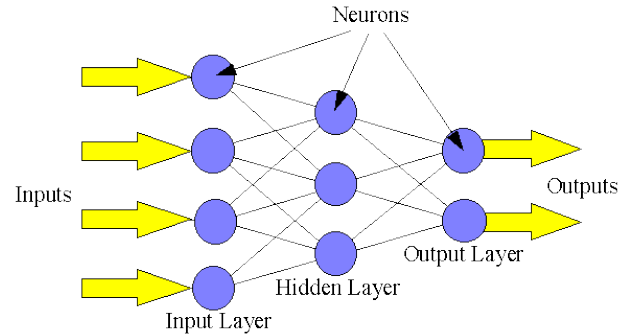
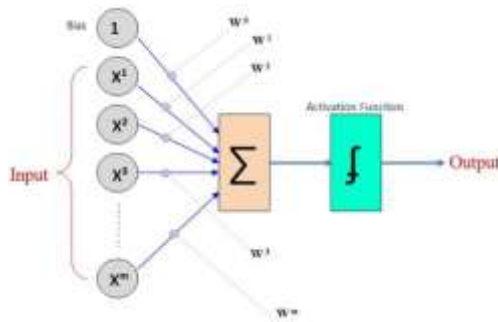
Experimental data

Simulated data

$?,?(N_e, N_\mu, N_h, S\dots)$ \Leftarrow $E, A(N_e, N_\mu, N_h, S\dots)$

1. Green and blue are not the same!
2. Identification of primary particle type
3. Estimation of primary particle energy
4. Background rejection
5. Genome analysis

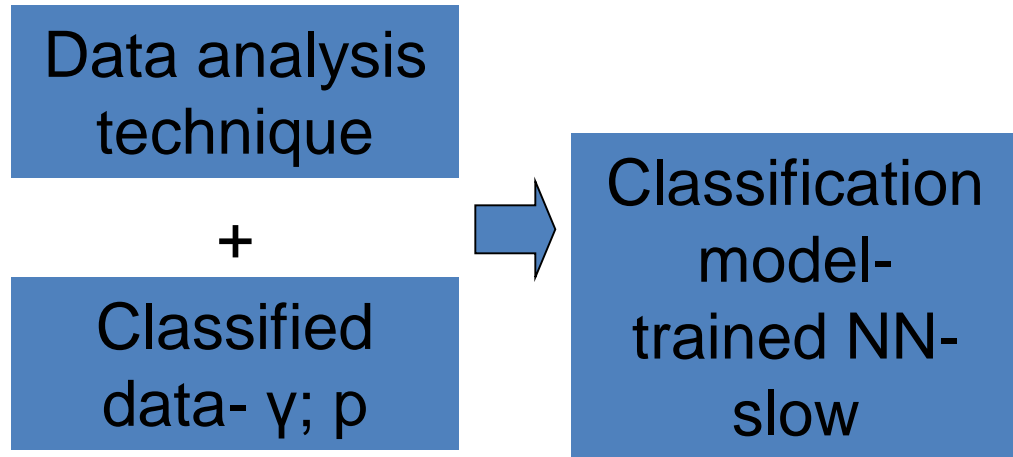
Why Neural Networks?



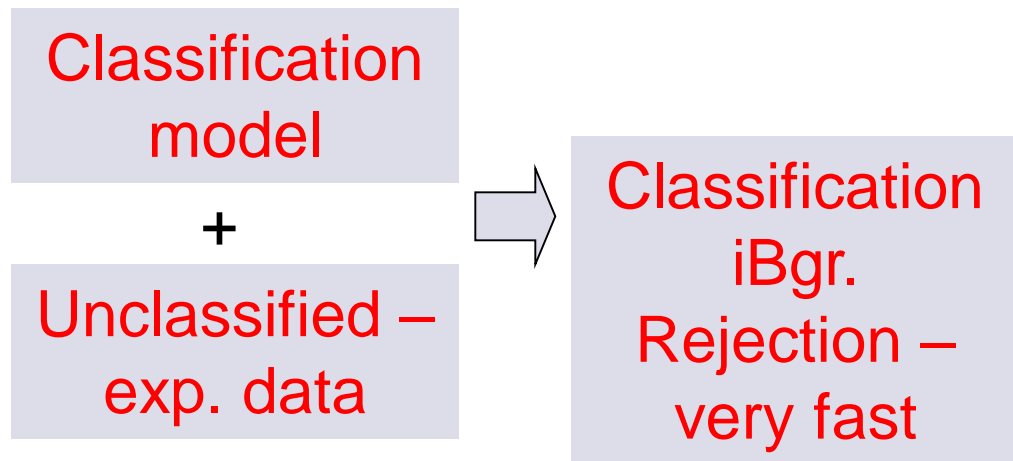
1. Neural Networks, like a Bayesian models, belong to the general class of nonparametric methods that do not require any assumption about the parametric form of a statistical model they use;
2. Are appropriate technique for classification and estimation tasks;
3. Are able to treat multidimensional input data;
4. Neural networks can easily deal with large amounts of training data experimental (millions of events);
5. Robustness and quality of prediction : Neural network methods if properly used approach Bayesian methods!
6. After troublesome training the implementation phase is very fast and can be made with hardware accelerators!
7. Retraining with new acquired knowledge is easy and contain in the new coefficient of NN, can be easily and save distributed among world (Armenian network project!)

Training and Implementation phases


- Step 1: Train some model on classified data- MC images



- Step 2: Apply trained model to unclassified data to obtain signal



Neural Chip SAND in online data processing of extensive air showers



- The neural chip SAND (Simple Applicable Neural Device) was designed to accelerate computations of neural networks at a very low cost basis, due to the fact that only few peripheral chips are necessary to use the neural network chip in applications. Four SAND-chips were implemented on one PCI-board. The board is highly usable for hardware triggers in particle physics. The performance of a SAND-PCI-board is 800 Mega Connections per Second due to four neuro-chips, each with four parallel 16 bit multipliers and 40 bit adders. SAND is able to implement feedforward neural networks with a maximum of 512 input neurons and three hidden layers. Kohonen feature maps and radial basis function networks may be also calculated. The application of the SAND-PCI-board is proposed for cosmic ray physics to allow online analysis of extensive air showers. [?]
- Computer Physics Communications 126 (2000) 63–66, 2000 Elsevier Science

Common Drawbacks in NN Training Process

1. The central issues in an ANN implementation remain the net training algorithms and strategies, which, in general, should not depend on the particular problem specifics to be solved and on data samples generated for the training purpose.
2. The main aim of the NN training is to learn the general rule for the problem solution by processing finite samples available for training and to achieve acceptable (reasonable) performance (generalization) when applied to the control (independent) events not used for the NN training.
3. In practice, the network which performs best on training sample, is not obligatorily the best on control sample, even more, if the overfitting occurs, such a network will fail processing control events. These are the questions about robustness and reliability of NN training which have to be addressed by techniques developed to overcome such kind drawbacks as overtraining control and "best" NN selection.

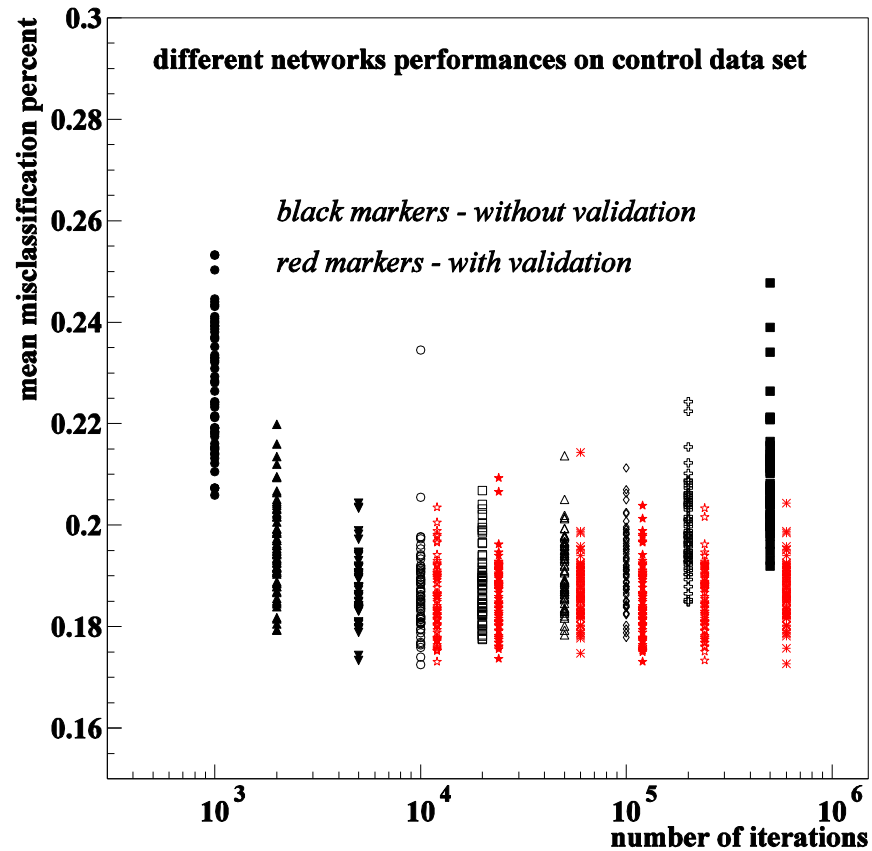
ANI package strategies of NN training

<http://www.crd.yerphi.am/Download>

[ANI#Download](#) (cmz and exe files,
manual)

1. Learn a general rule and not particular training sample: continuous overtraining control;
2. MRSES(Multistart Random Search with Early Stop) and RSV (Random search with validation – cure for overtraining). A committee of several networks is used to generate a voting procedure for choosing best for each event, training started from the random points in the space of net parameters;
3. RSV strategy: train single network with runtime validation for controlling overtraining, use not training sample error but error your network made on independent control sample!
4. Special type of “mapping networks” for selected best signal domain; using signal-to-noise ratio in NN training as quality function;
5. US Patent application 38509/0003: MULTIVARIATE RANDOM SEARCH METHOD WITH MULTIPLE STARTS AND EARLY STOP FOR IDENTIFICATION OF DIFFERENTIALLY EXPRESSED GENES BASED ON MICROARRAY DATA

The Efficiency of Run-Time Validation



To understand what NN is doing physicist have start with Feature Selection

1. Binominal NP non tractable problem;
2. Selecting best single features;
3. Correlation analysis – selecting best pairs;
4. Test best pair + best singles;
5. Random search in multivariate feature space with return at “bad” step and tuning of step size;
6. Multiple start and early stop of random search;
7. Bayesian risk estimate on each step: Empirical error calculation with independent control sample;
8. Comparisons of Bayesian error and mpirical error of Nntraining.

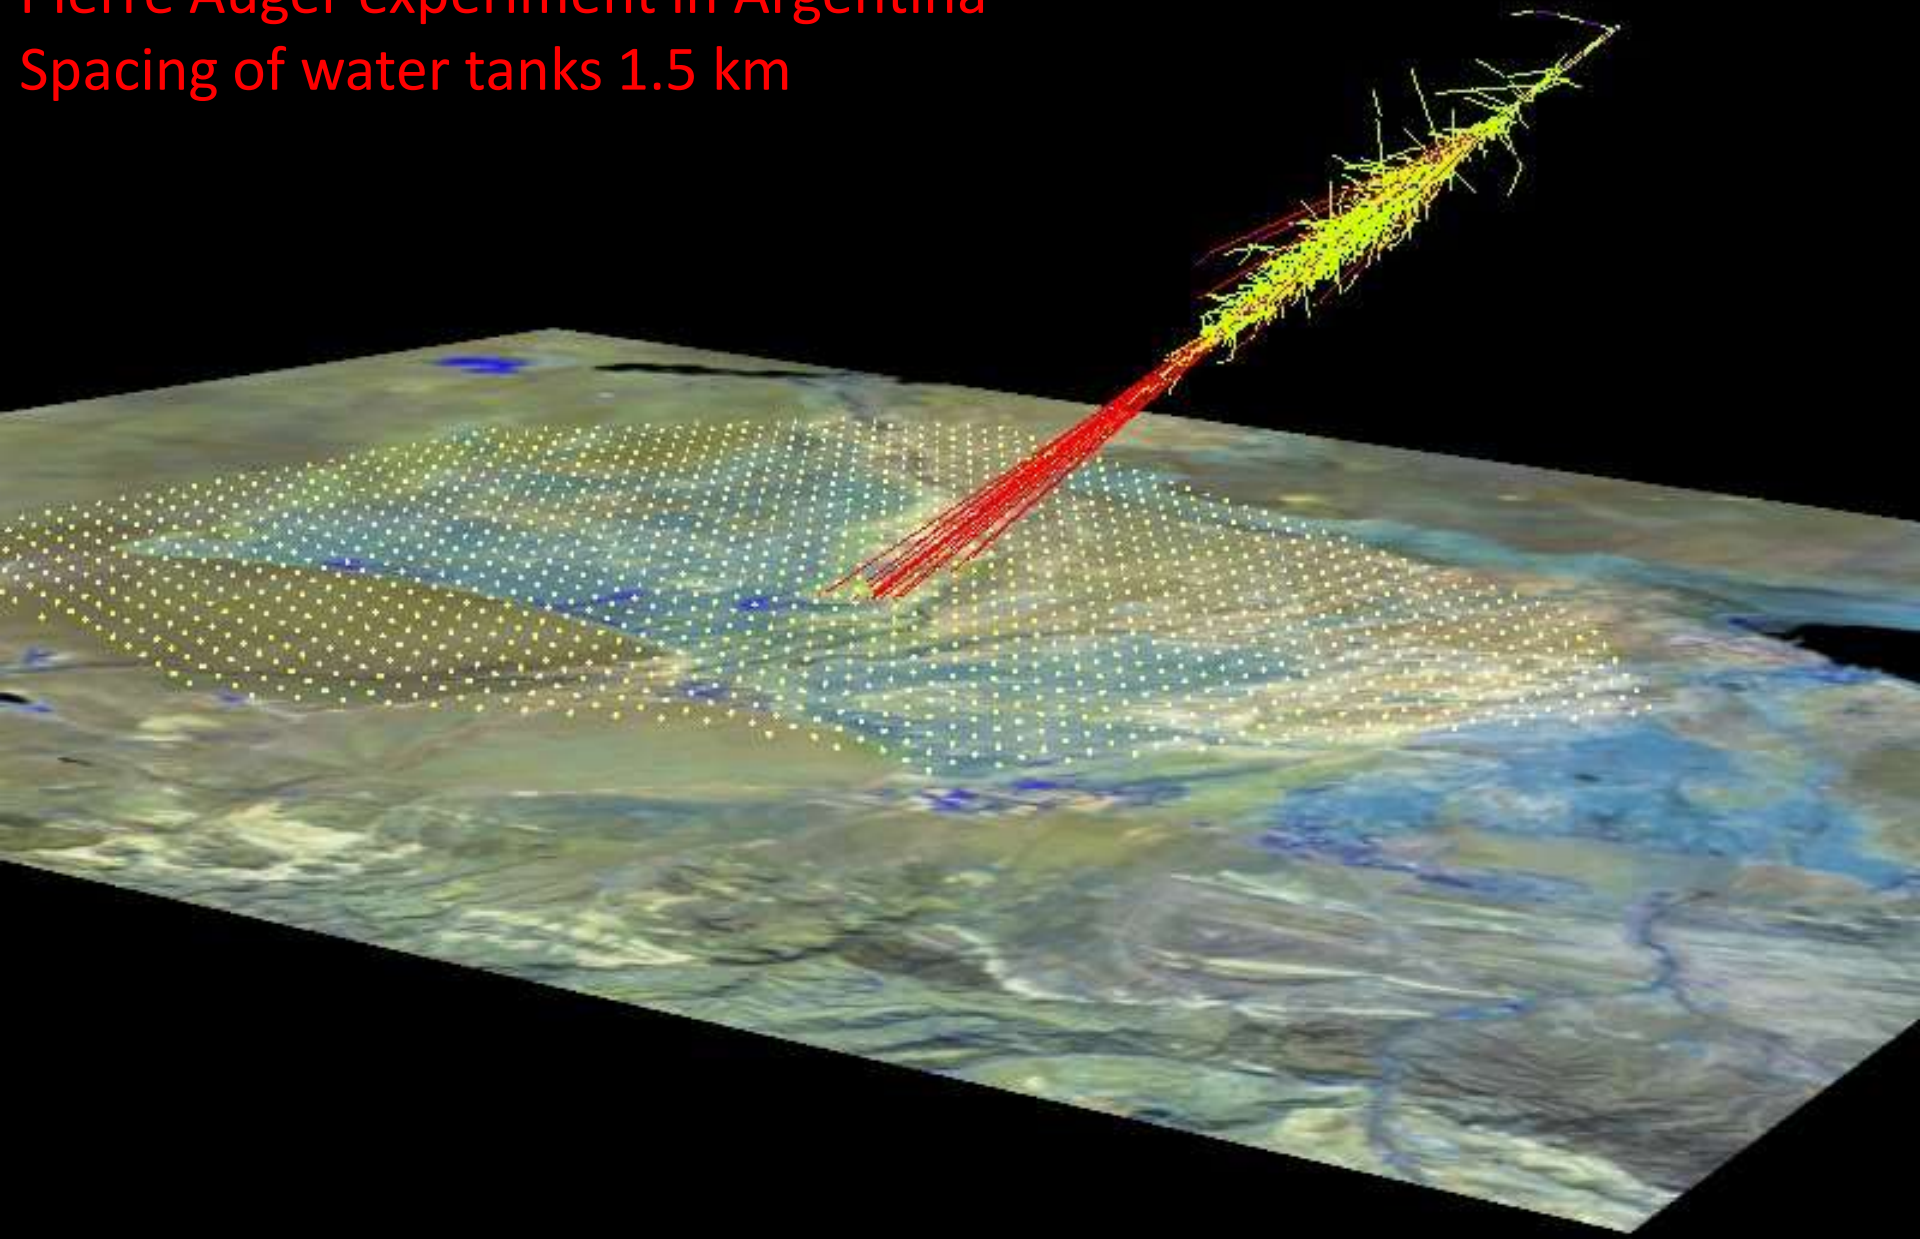
Стандартная модель — возможно, самая совершенная теория, описывающая материю, все, что вокруг нас, иногда с очень высокой точностью. Она относительно проста и даже элегантна

- Вещество состоит из атомов, атомы состоят из ядер и электронов. Ядра состоят из протонов и нейтронов, которые состоят из u - и d -кварков.
- Электроны удерживаются в атоме электромагнитным взаимодействием, его переносчиком является фотон. Протоны и нейтроны в ядре и кварки внутри протонов и нейтронов удерживаются сильным взаимодействием, его переносчиками являются глюоны. Наконец, существует еще слабое взаимодействие, приводящее, например, к бета-распадам ядер, а его переносчиками являются W - и Z -бозоны.
- Существуют частицы, которые участвуют только в слабом взаимодействии — нейтрино. Они взаимодействуют так слабо, что могут пройти через Землю и через Солнце. Через каждого из нас каждую секунду пролетают сотни триллионов нейтрино, а мы этого не замечаем.
- Взаимодействие с бозоном Хиггса дает массы всем фундаментальным частицам.
- Таким образом, окружающее нас вещество состоит всего из четырех «кирпичиков»: u - и d -кварков, электронов и нейтрино. Их называют первым поколением кварков и лептонов.
- Лептоны — это частицы, не принимающие участие в сильном взаимодействии. Природа создала еще два поколения кварков и лептонов, имеющих много большую массу. Их вокруг нас практически нет, но они могут возникать при взаимодействии частиц первого поколения и быстро распадаются в конечном итоге на частицы первого поколения.
- У всех частиц есть античастицы. Сильное, электромагнитное и слабое взаимодействия обладают так называемой калибровочной инвариантностью, что в значительной мере определяет их характеристики.

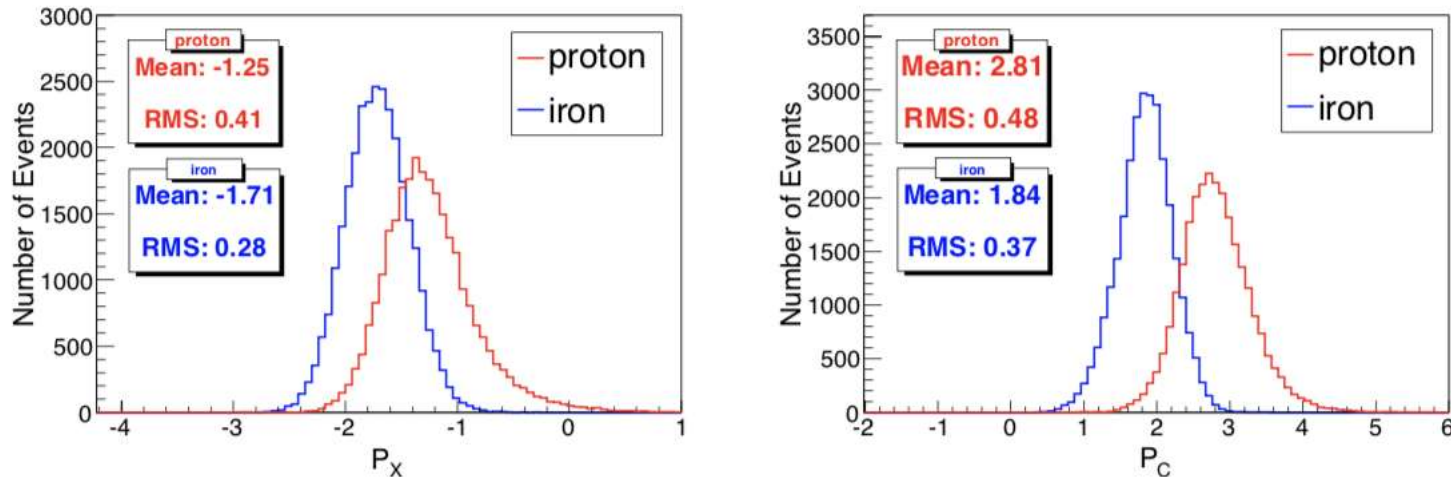
Стандартная модель не описывает того, чего мы не видим, а этого во Вселенной намного больше.

- Обычное вещество составляет всего лишь около 4% того, что есть во Вселенной, остальное — темная материя и темная энергия, природа которых неизвестна.
- У Стандартной модели есть еще и другие недостатки: слишком большое количество параметров, некоторые внутренние противоречия, гравитационное взаимодействие, которое действует на все объекты, имеющие энергию, не удастся включить в Стандартную модель.
- Поэтому большинство физиков считают, что должны быть явления за рамками Стандартной модели, и их поиски являются основным направлением исследований; В отличие от прошлых лет сейчас нет четких теоретических указаний, куда надо двигаться.
- Изучение космических частиц — еще одно важнейшее направление, например, поиски темной материи в подземных низкофоновых лабораториях и в процессах аннигиляции частиц темной материи в космосе.

Pierre Auger experiment in Argentina
Spacing of water tanks 1.5 km

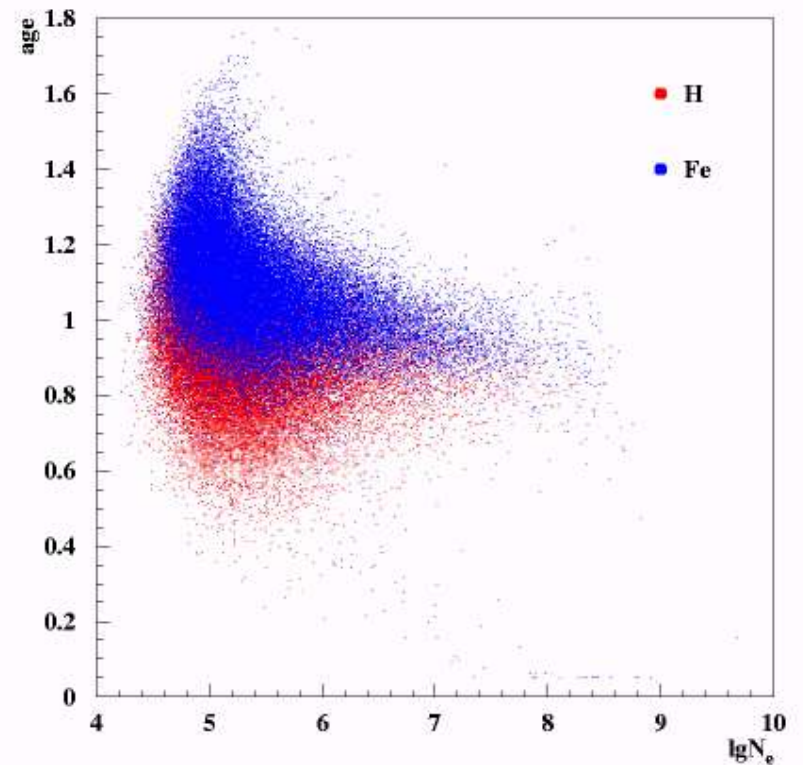
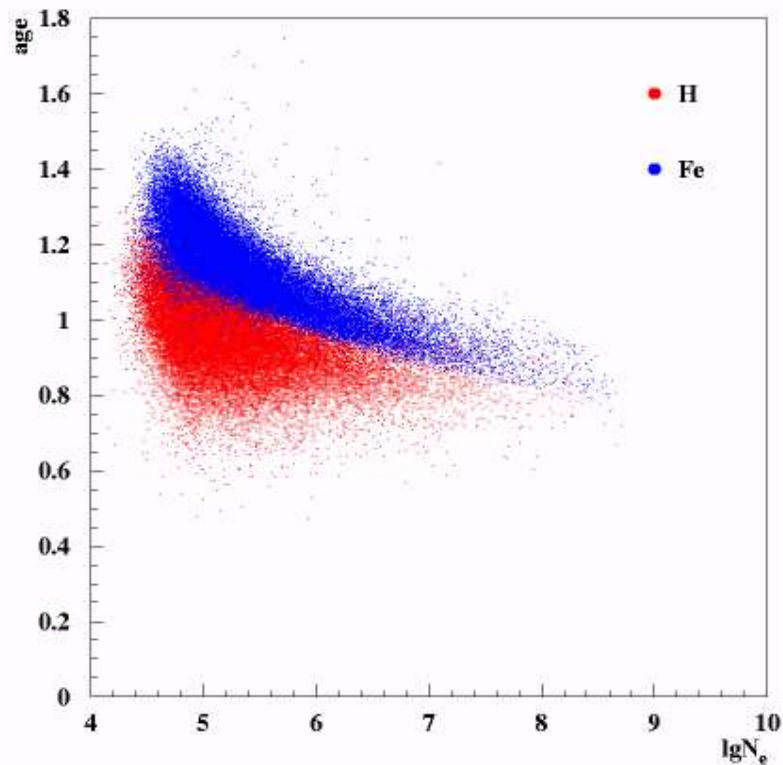


Proton and Helium Event Selection by Large High Altitude Air Shower Observatory(LHAASO) - consisting of three detector arrays: kilometer square array (KM2A) which includes the electromagnetic detector array and muon detector array, water Cherenkov detector array (WCDA) and wide field of view Cherenkov telescope array (WFCTA).

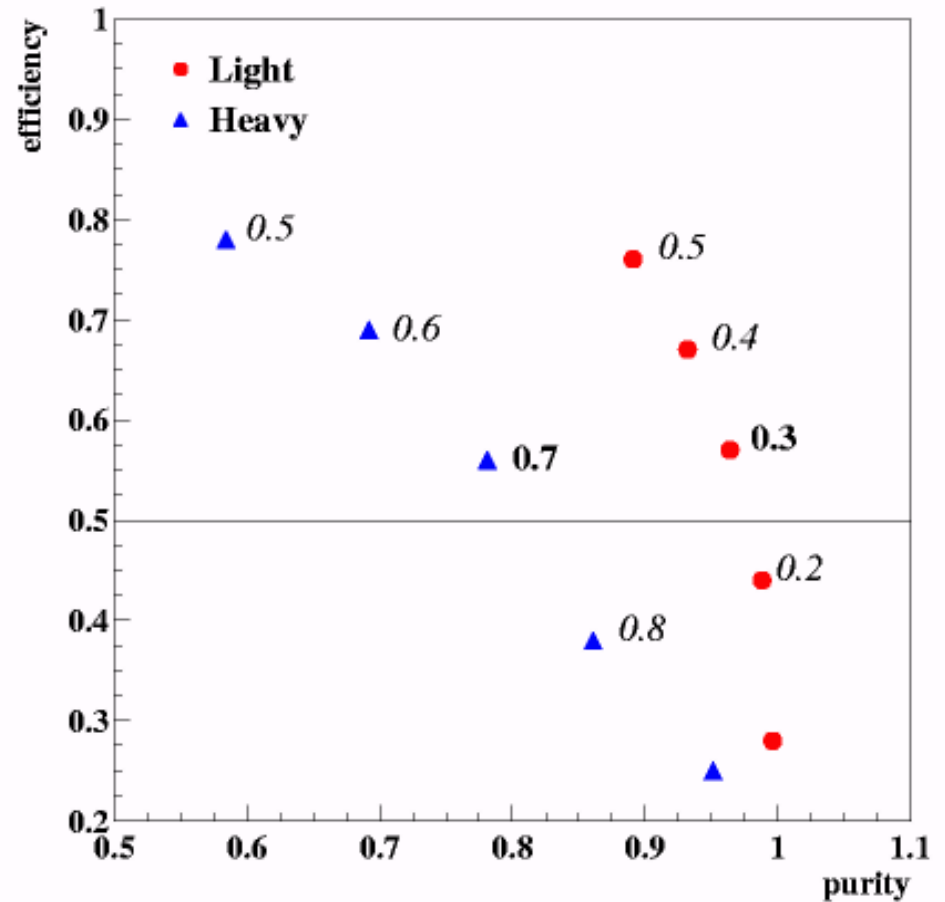
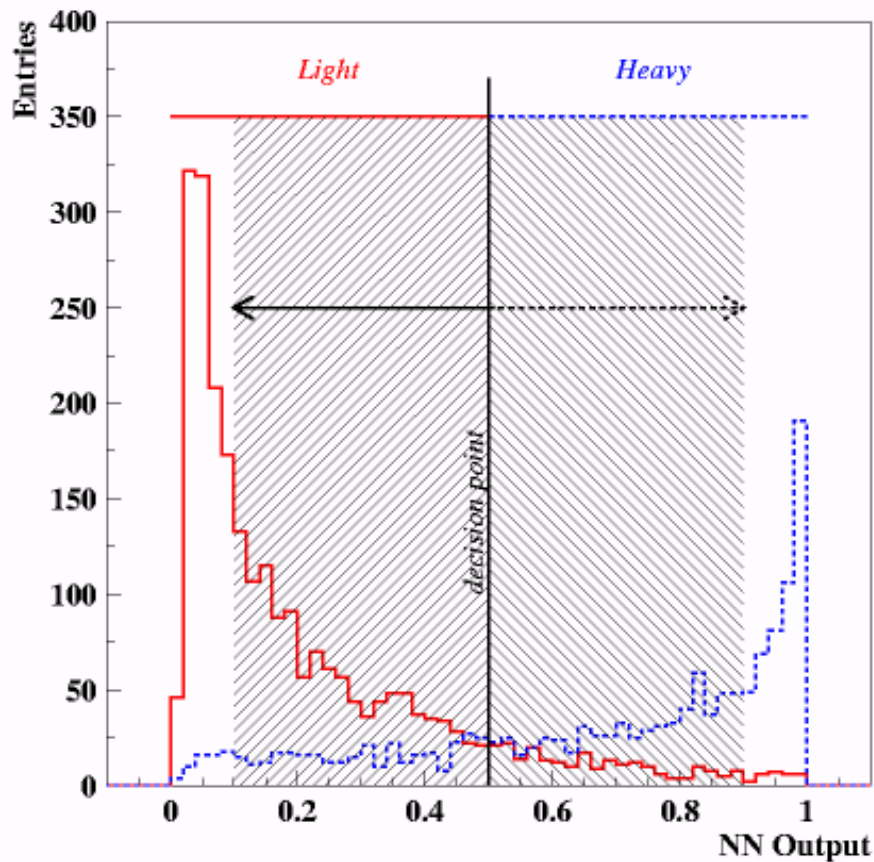


The distributions of mass sensitive parameters P_x (left) and P_c (right) for proton (red line) and iron (blue) initiated showers. $\Delta\theta$, the exactly parameter used to reconstruct the X_{max} , is applied instead of the reconstructed X_{max} . $\Delta\theta$ is the angular distance between the shower arriving direction and the gravity center of the Cherenkov image. After normalization, the structure of the mass sensitive parameter P_x is as follows: $P_x = \Delta\theta - 0.0103 \times R_p - 0.404 \times N_0^{pe}$
 R_p is the perpendicular distance between the telescope and the shower axis; and N_0^{pe} is shower energy. Moreover, the ratio of length and width of the Cherenkov image is also a traditional and effective parameter: $P_c = L/W - 0.0137 \times R_p + 0.239 \times N_0^{pe}$

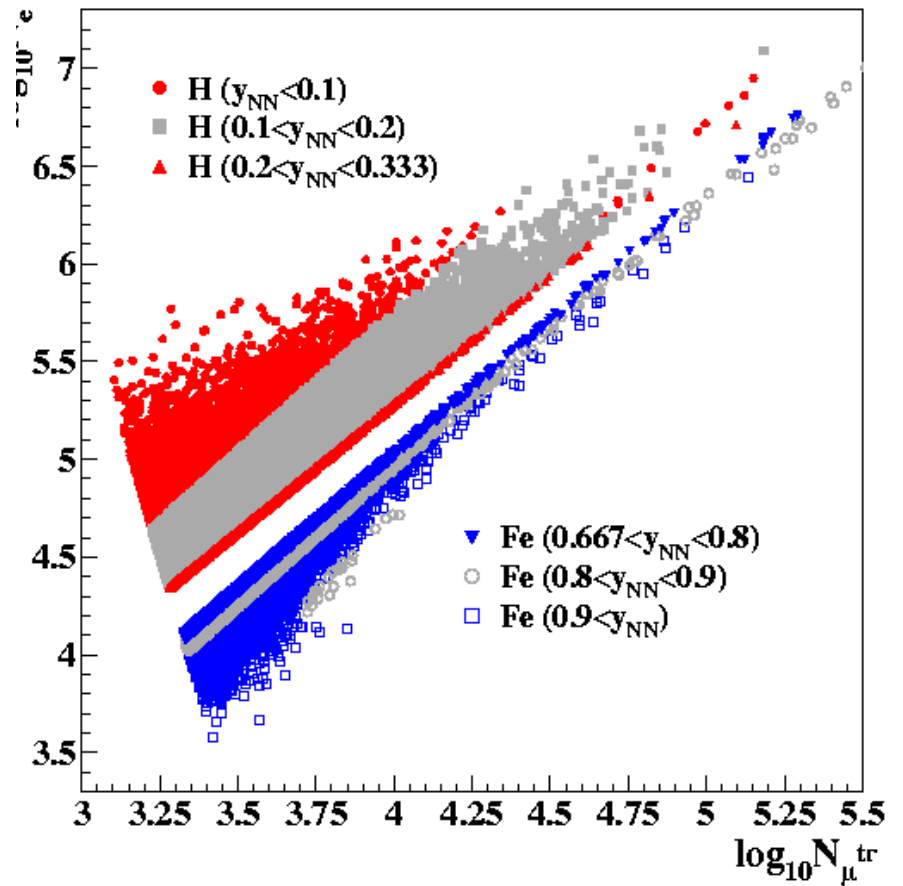
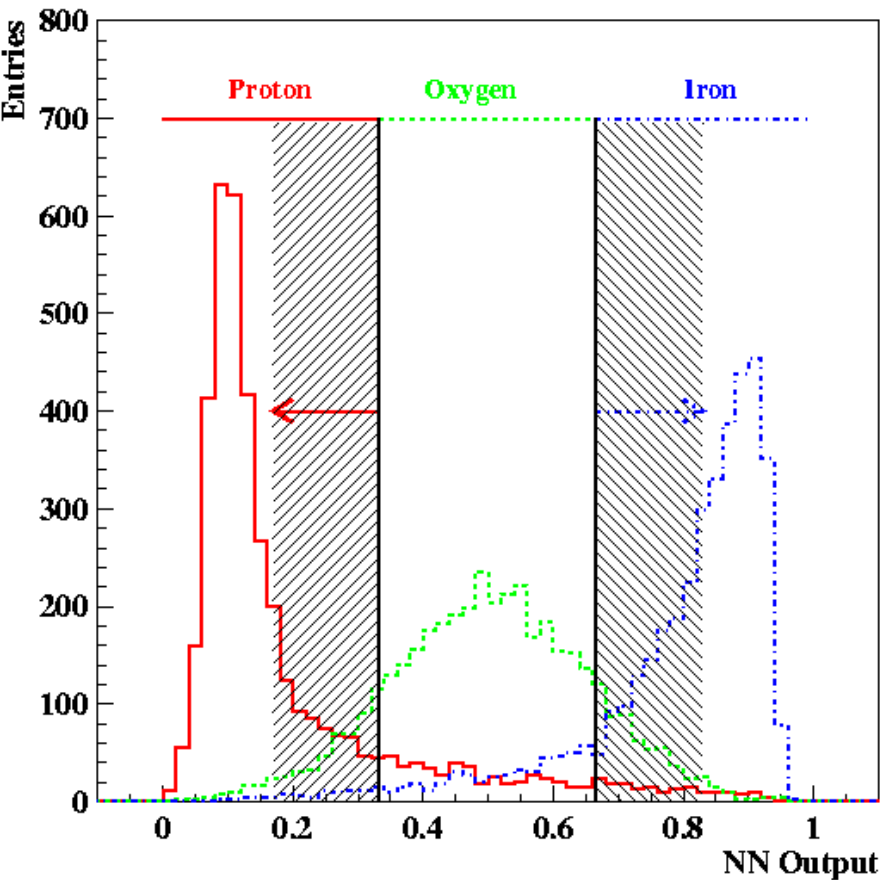
Scatter plot of Shower Size and Shape Parameters for light and heavy nuclei



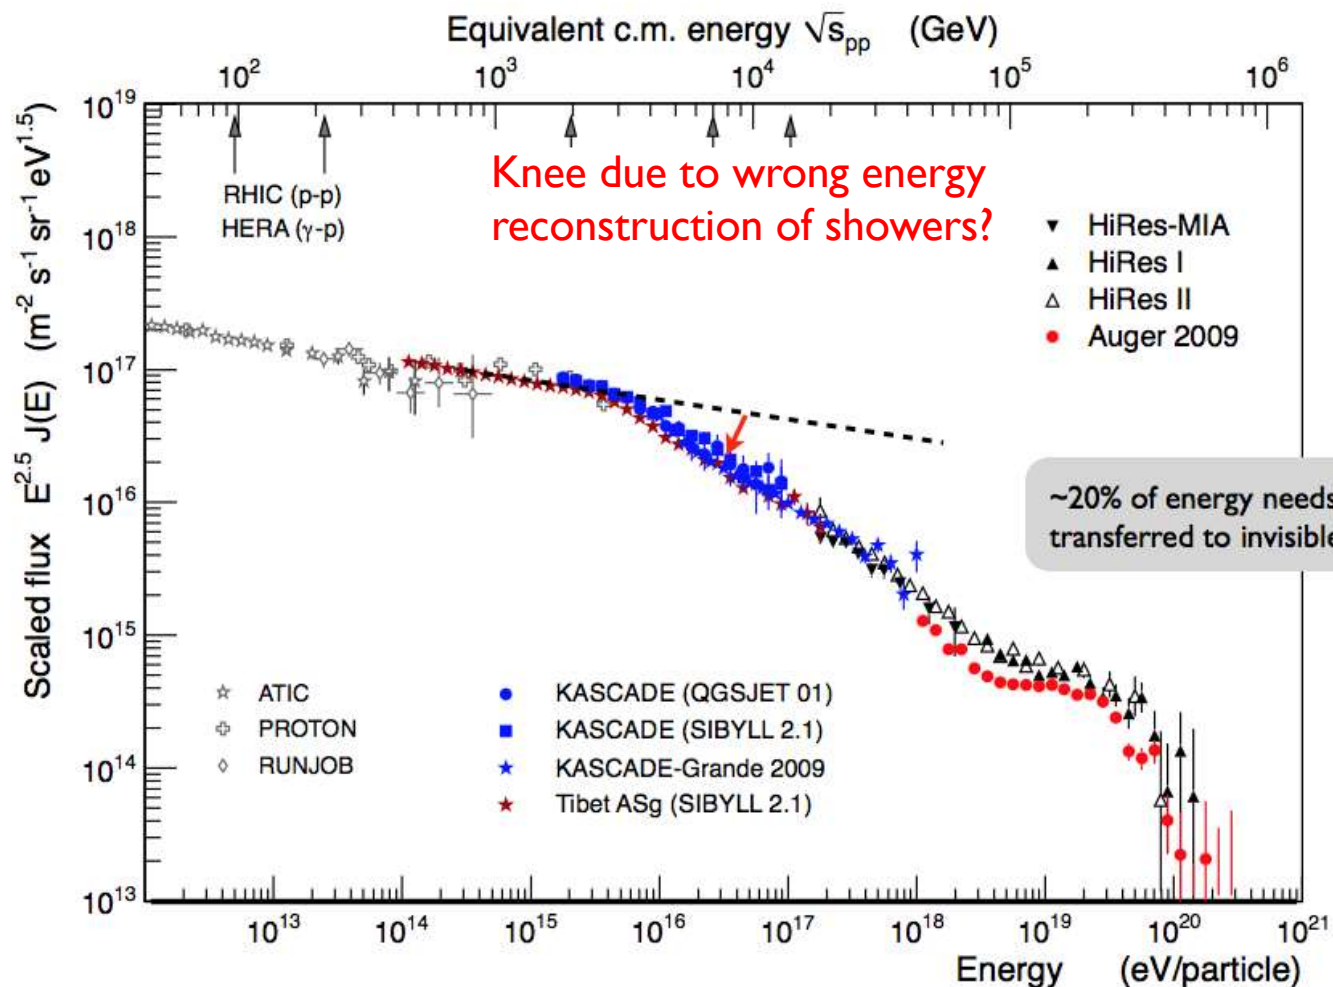
Partial spectra: light and heavy nuclei: 2-way Classification of MAKET-ANI data



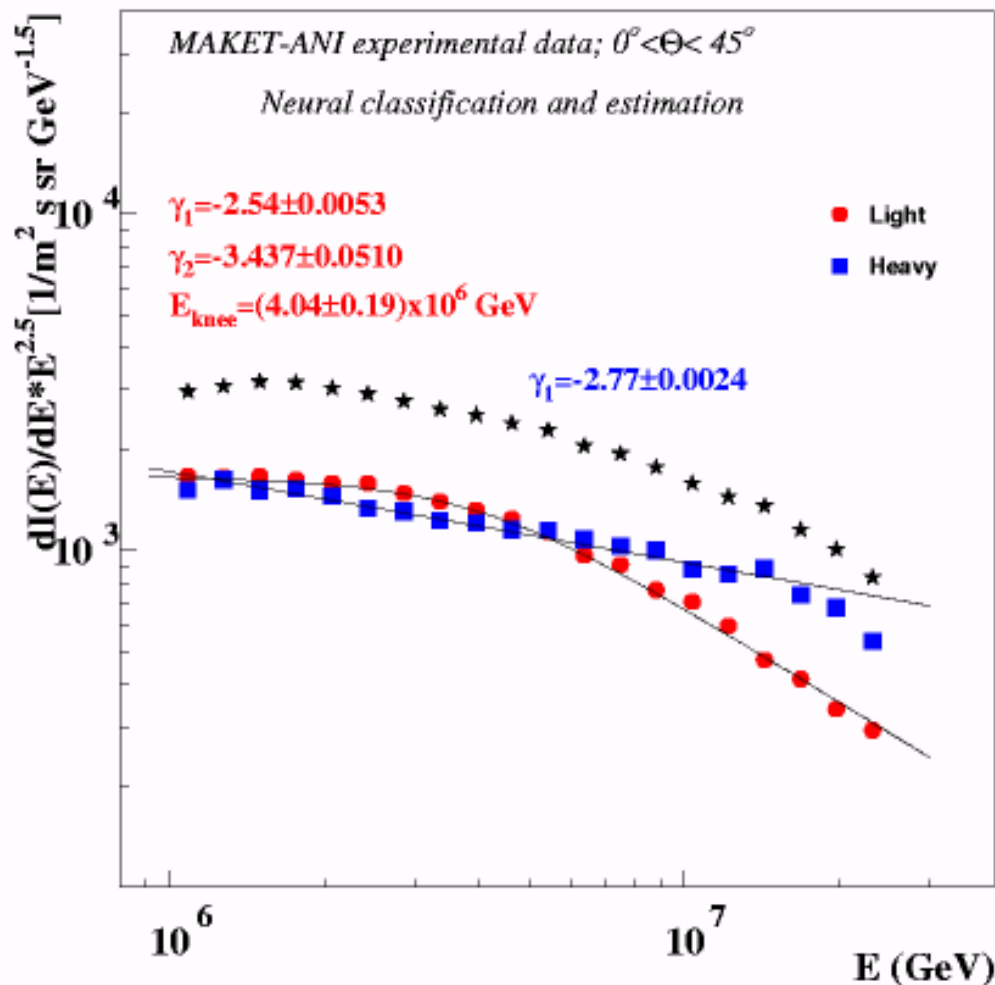
3-way KASCADE Data Classification



“Knee” limit of space accelerators or escaping energy?



Neural classification of the all particle energy spectra to Light and Heavy Nuclei



Credit, Chilingarian A., Hovsepyan G. et.al., (2004), ApJ, 603, L29



On 22 September 2017, [IceCube](#) detected a neutrino that was special: Its very high energy (roughly 290 teraelectronvolt) indicated that the particle might have originated from a distant celestial object. Scientists were also able to identify its incoming direction with high precision.

In fact, [Fermi-LAT](#), a space observatory that conducts all-sky surveys, reported that the direction of the neutrino was in line with a known gamma-ray source in an active state: the blazar TXS 0506+056. What is more, [MAGIC](#), a 17-meter twin telescope that probes high energy



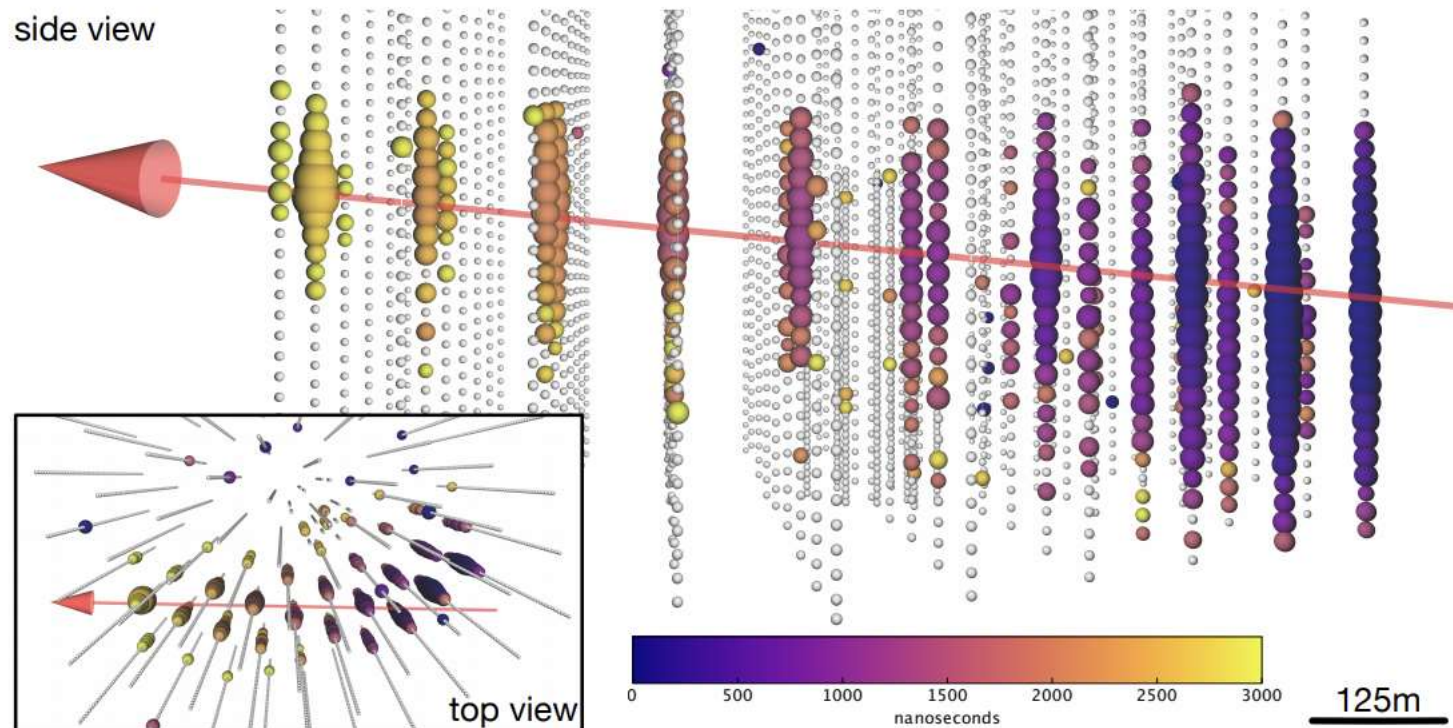
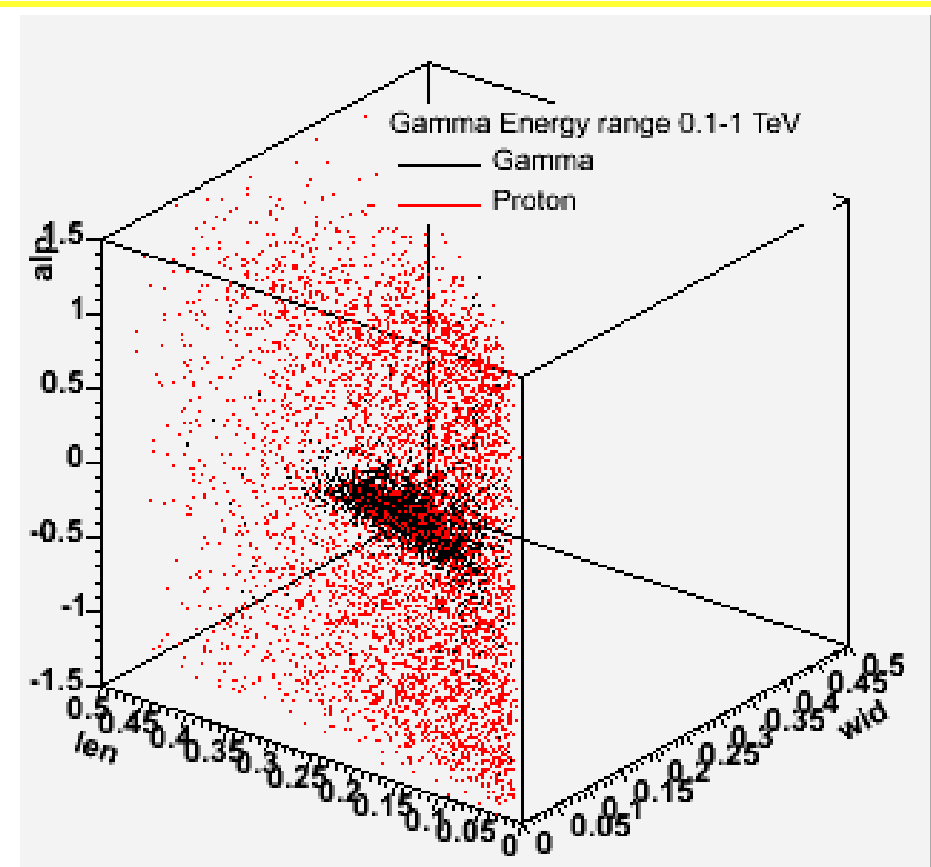
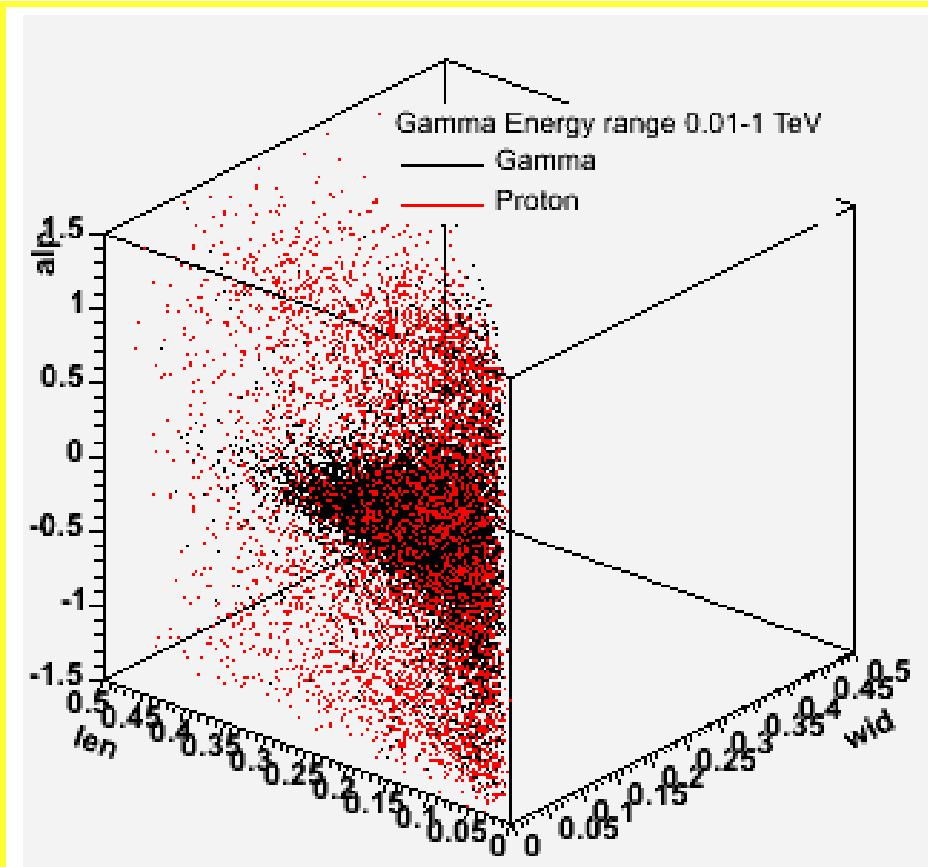


Figure 1: **Event display for neutrino event IceCube-170922A.** The time at which a DOM observed a signal is reflected in the color of the hit, with dark blues for earliest hits and yellow for latest. Time shown are relative to the first DOM hit according to the track reconstruction, and earlier and later times are shown with the same colors as the first and last times, respectively. The total time the event took to cross the detector is ~ 3000 ns. The size of a colored sphere is proportional to the logarithm of the amount of light observed at the DOM, with larger spheres corresponding to larger signals. The total charge recorded is ~ 5800 photoelectrons. Inset is an overhead perspective view of the event. The best-fitting track direction is shown as an arrow, consistent with a zenith angle $5.7^{+0.50}_{-0.30}$ degrees below the horizon.

Combining Shape and Orientation we'll achieve large Q-factors (σ)



The Wedge cut (supercut0)

Chilingarian, A.A. and M.F. Cawley , Multivariate analysis of Crab Nebula data, Note to Whipple collaboration from July 5, 1990.

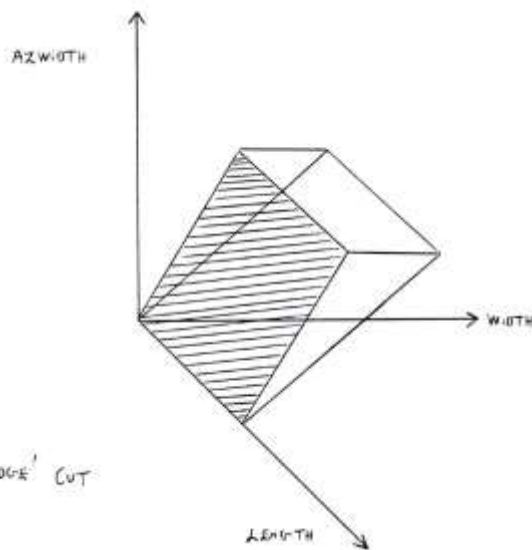
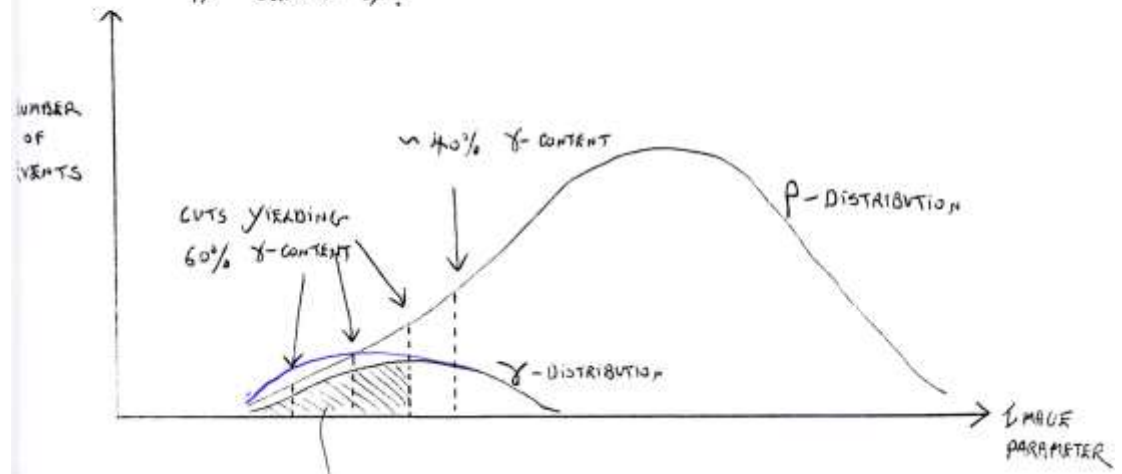


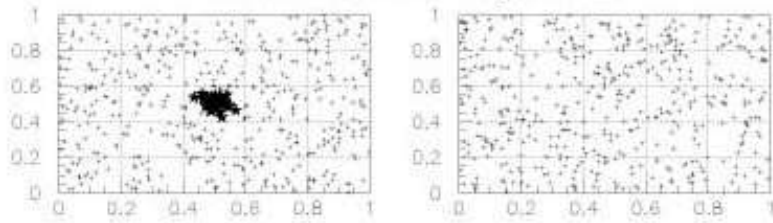
Fig. 6 1-D ILLUSTRATION OF IDEAS DISCUSSED IN SECTION 4.



First detection of Crab nebula by the Whipple collaboration, contained in the famous 1988-1989 data files, consisting of 65 ON-OFF pairs, more than 1 million images, $\sigma = 27$

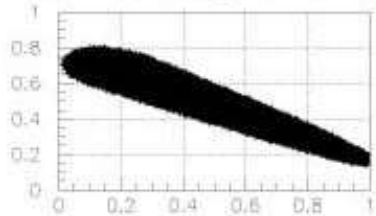
Artificial intelligence(machine learning) approach: New Type of NN – Mapping Networks -Maximizing Signal Significance – by optimizing the shape of Gamma Domain

Deterministic algorithm

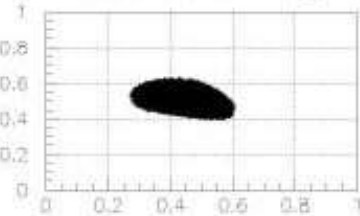


SIGNAL ON: 50 sign. + 450 backg.

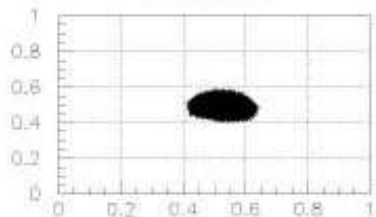
SIGNAL OFF: 450 backg.



A=40, $\sigma=5.37$



A=20, $\sigma=6.27$

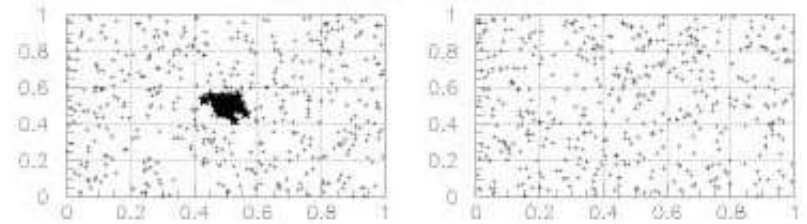


A=10, $\sigma=6.49$




A=5, $\sigma=6.82$

genetic algorithm

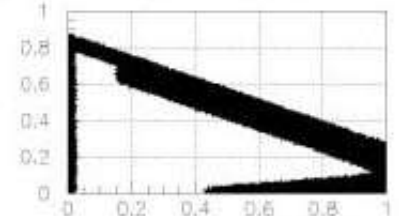


SIGNAL ON: 50 sign. + 450 backg.

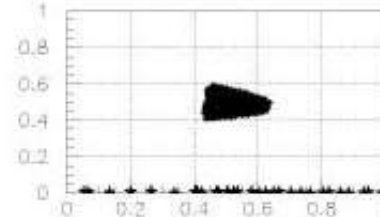
SIGNAL OFF: 450 backg.



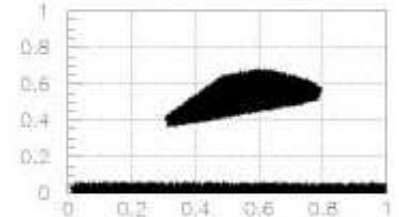
Crossover: $\sigma=6.87$



Crossover: $\sigma=6.87$



Mutation: $\sigma=7.22$



Mutation: $\sigma=7.32$

Comparison of the different background rejection methods WIPPLE detection of CRAB, 1988-1989

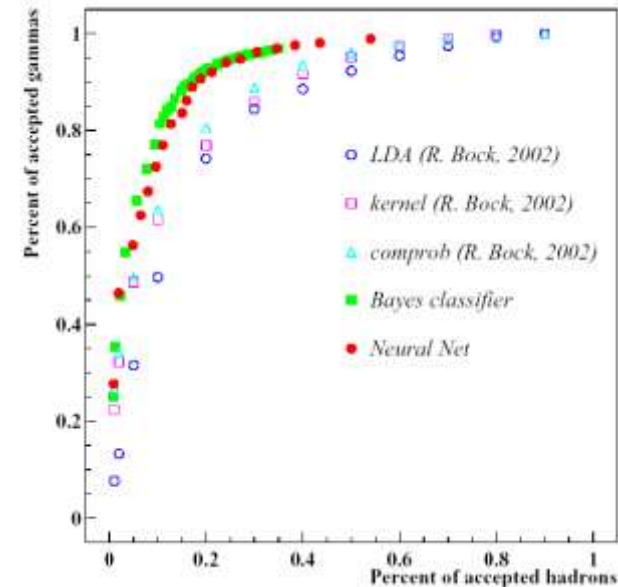
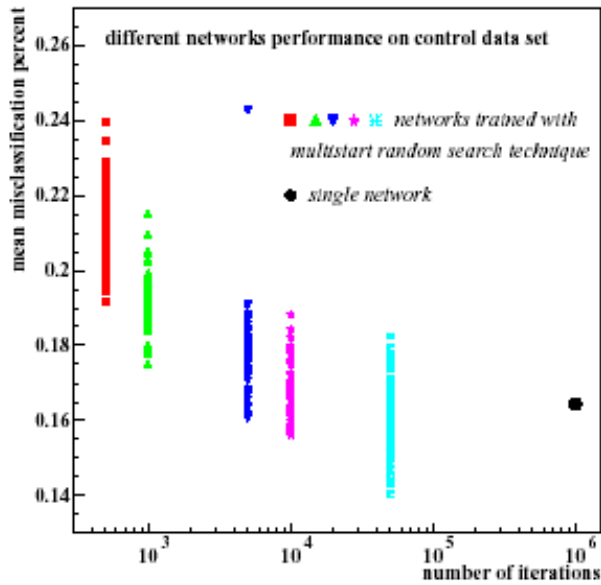
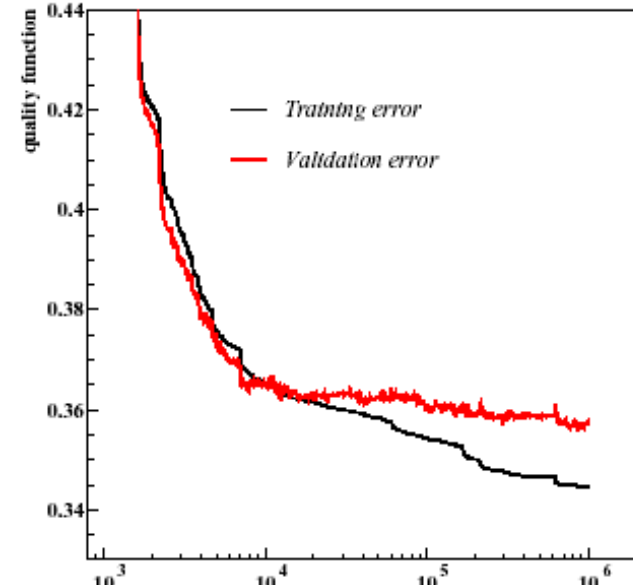
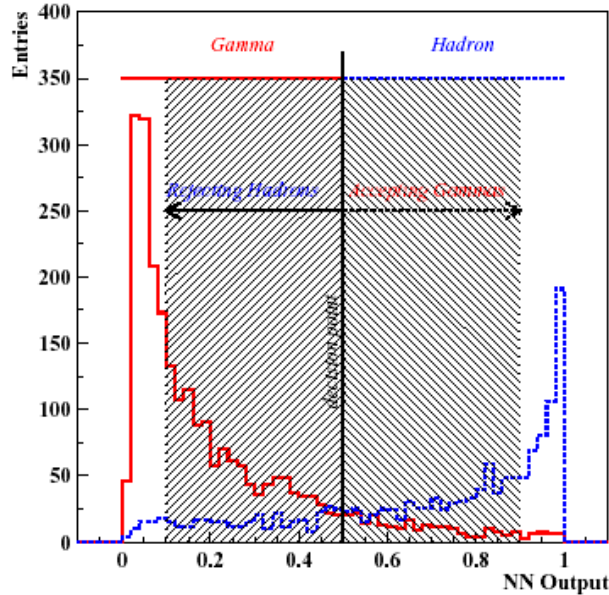
	N_{on}^*	N_{off}^*	σ	DIFF	DIFF/ N_{off}^*	N_{off}^*/N_{off}
Raw	506255	501408	4,8	4847	0.01	
Azwidth	14622	11389	20.4	3233	0.28	0.0227
Wedgecut*	6017	3381	27.2	2636	0.78	0.0067
Supercut**	4452	1766	34.3	2686	1.52	0.0035
Neural***	6278	2858	35.8	3420	1.20	0.0057
4::5::1						

*Chilingarian, A.A. and M.F. Cawley. Application of multivariate analysis to atmospheric Cherenkov imaging data from the Crab nebula. Proc. 22 ICRC, 1, 460-463, Dublin, 1991.

**Punch, M., C.W. Akerlof, M.F. Cawley, et. al.. Supercuts: an improved method of selecting gamma-rays. Proc. 22nd Internal. Cosmic Ray Conf., Dublin, 1, 464-467, 1991

***Chilingaryan A. A., Neural classification technique for background rejection in high energy physics experiments, Neurocomputing, 6, 497, 1994.

MRSES Training of NN to Reject Hadrom Background in Detecting AGN and SNR

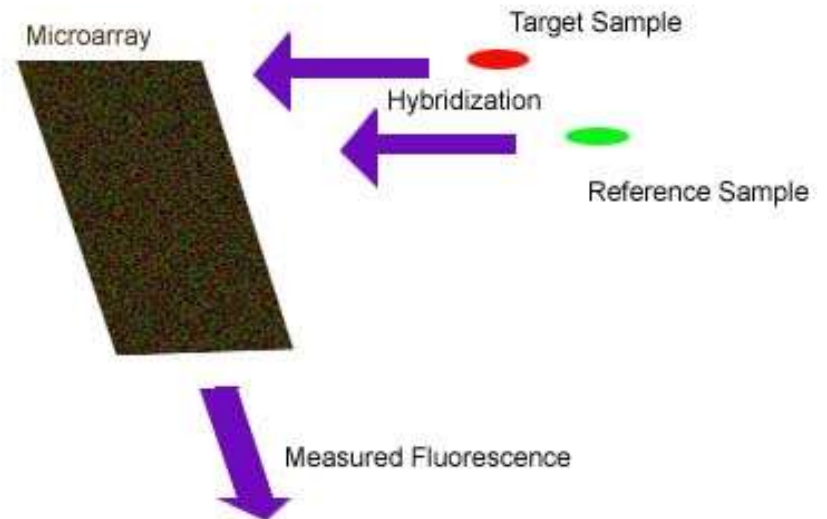
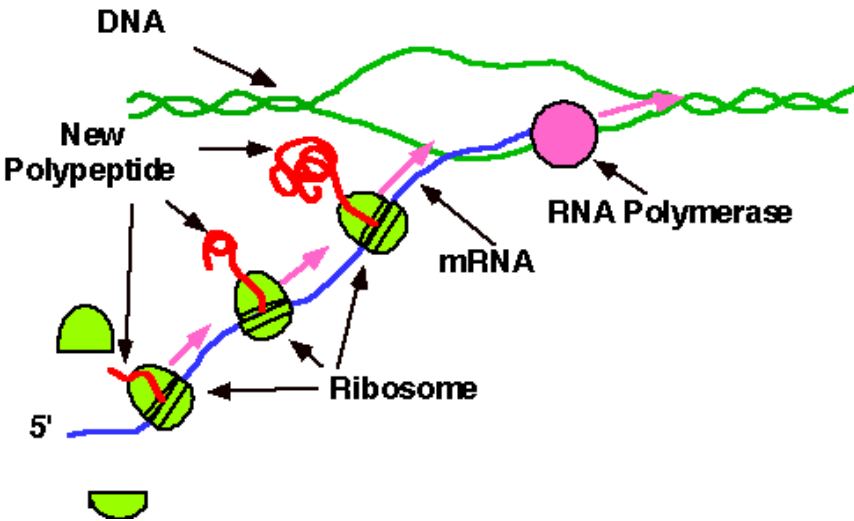


Why is so important to reject background

- “ON” sample- obtained with telescope axes oriented in direction of the putative gamma-ray source and
- “OFF” – sample, obtained by pointed telescope axes in direction of the same celestial co-ordinates, but after the source already leave the destination;
- If the field of view of the telescope is enough large it is possible to take “ON” and “OFF” scans simultaneously, selecting within field of view samples pointed to source and to “empty” space;
- Best estimate of $SIGNAL = ON - OFF = 10100 - 10000 = 100$;
- SIGNIFICANCE OF SIGNAL DETECTION
- $SIGNAL-TO-NOISE RATIO = SIGNAL/OFF = 100/10000 = 0.01$;
- Let's assume that we succeed to reject 99% background keeping 50% signal!
- $ON = 150$; $OFF = 100$; $SIGNAL = 150 - 100 = 50$
- $SIGNAL-TO-NOISE RATIO = SIGNAL/OFF = 50/100 = 0.5$;

Microarray Technique

Coupled Transcription and Translation

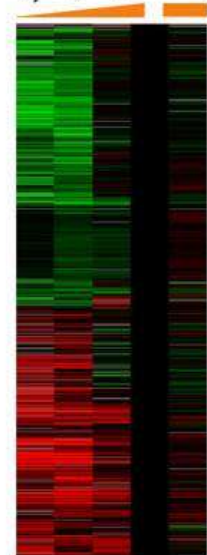
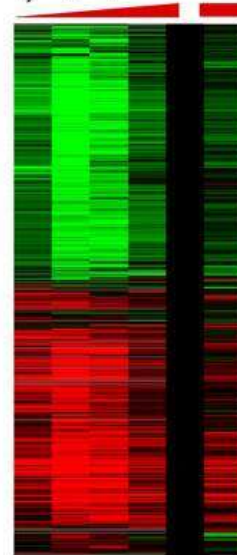


A. 25°C to 37°C

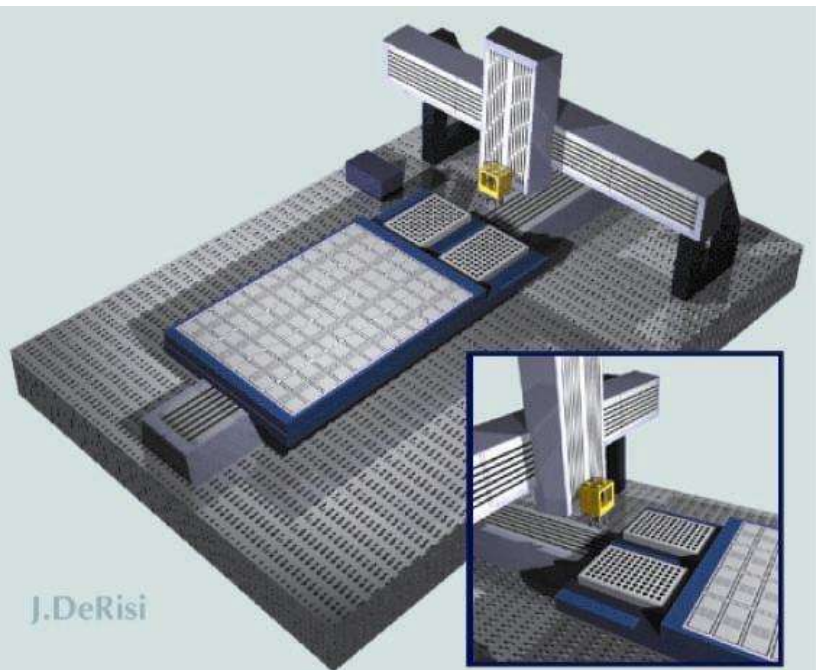
B. 29°C to 33°C

5 minutes
15 minutes
30 minutes
60 minutes
steady-state at
37°C vs. 25°C

5 minutes
15 minutes
30 minutes
steady-state at
33°C vs. 29°C



>6X repressed >6X induced



Selection of the best subset of genes (20 best from 1000) NP-complete problem

Class 1

	S1	S2	S3							Sn
gene1										
gene2										
...										
gene k										
...										
...										
gene p										

Class 2

	S1	S2	S3							Sm
gene1										
gene2										
...										
gene k										
...										
...										
gene p										

$f(20 \text{ genes}) \sim f(R_m) * C_{20}^{1000} = 1000!/20!/980! \sim 10^{60}/10^{18} = 10^{42}$ operations; One element of covariance matrix calculate in 1 mcsec, then time required on 10 Pfl CPU $\sim 10^{19}$ sec $\sim 10^{12}$ years;

Age of Universe is $1.37 * 10^{10}$ years

MRSES Heuristic: $f(\text{MRSES} - 5\text{genes}) \sim f(R_m) * N_{\text{iterat}} * N_{\text{cycles}} \sim 25 * 500 * 10,000 = 1.25 * 10^8$ operations: 12,5 seconds;

MRSES NET Training 1

1. split available sample in to training and validation samples by the ratio of 2:3 and 1:3 respectively.
2. fix the number of networks to be trained N_{cycle}
3. fix the number of iterations N_{iter} .
4. select the initial weights of the network randomly from gaussian distribution with prechosen mean μ and σ variance (σ is a small number).
5. set the initial quality function to a very large value.
6. select the iteration step size randomly from the prechosen $\Delta v \in R$ interval.
7. perform a random iteration step in the multidimensional space of NN weights from the initial point to modify all weights of randomly chosen neuron, the alternation of weights is performed according to the following:

MRSES NET Training 2

$$\vec{V}_i = \vec{V}_{i-1} + Q_{i-1}^p \cdot (RNDM - 0.5) \cdot \Delta v; \quad i = 1, N_{iter} \quad (1)$$

were \vec{V}_i is the vector of NN weights obtained at i-th iteration step, Δv is step size and RNDM is a random number from [0-1] interval. The term Q_{i-1}^p introduces dependence of value of random step on the already achieved quality function and controls the strength of this dependence, $p = 0, 1, 2$.

8. calculate the objective (quality) function at each step by presenting all the training events to Neural Network:

$$Q_i = \frac{1}{M_{events}} \sum_k (OUT_k - TRUE_k)^2 * W_k, \quad k = 1, M_{events}, \quad (2)$$

were OUT_k is the actual output of NN, $TRUE_k$ is the corresponding goal value of k-th input vector from the training set, W_k is event weight, M_{events} is the number of training events.

Mrses training 3

9. If $Q_i \leq Q_{i-1}$, then the vector \vec{V}_i is kept as new weights of NN and the next step is initializing from point \vec{V}_i in multidimensional space of NN weights, otherwise - return to the previous point is implemented and a new random step is performed.
10. if $i = N_{iter}$, stop random iterations, save the obtained NN weights, otherwise go to 7,
11. repeat steps 4-10 N_{cycle} times (train N_{cycle} networks),
12. apply each trained network for the validation sample classification,
13. select the network best performed on the validation set.

YerPhi publications on ML (1)

- A.Chilingarian, **Analysis of Data Interpretation Methods for ANI Experiment**, Problems of Nuclear Science and Technology, techniques of physics experiment series, **3/12/1982**
- A. Chilingarian, **Identification of High Energy Particles as Pattern Recognition Problem**, Problems of Nuclear Science and Technology, techniques of physics experiment series, **4/12/1982**
- A. Chilingarian, **On the Effectiveness of Statistical Methods of High Energy Particle Identification**, Preprint YerPhi-582(69), 1982
- A. Chilingarian, **Development of Statistical Methods in Cosmic Ray Physics** Proceedings of the 18th ICRC, Vol. **5**, Bangalor, India, 1983
- N. Akopov, S. Harutunyan, A. Chilingarian, Sv. Harutunyan, et al., **The Applied Program Package for Multivariate Statistical Analysis**, Proceedings of the 6th School of Physics Calculation Methods, (52-55), 1985
- A. Chilingarian, S. Galfayan, **Calculation of Bayesian Risk by Means of KNN Probability Density Estimation** , “ Problems of Control”, issue. 66, Vilnius, Litvania, (64-78), 1985.
- V. Avakyan, V. Matevosyan, A. Chilingarian, N. Chilingarian, et al., **The Bayesian Identification of Cosmic Ray Hadrons**, Preprint YerPhi -933(84), 1986
- A. Chilingarian, N. Khudonyan, D. Sahakyan, G. Zazyan, **Recognition of Correlated Patterns with Spin Glass Like Models**, Preprint YerPhi-992(42), 1987

YerPhi publications on ML (2)

- A. Chilingarian, G. Zazyan, **A Classification Method of Determination of Mass Composition of Primary Cosmic Rays**, Preprint YerPhi -1210(87), 1989
- A. Chilingarian, **Statistical Conclusions under Nonparametric A Priori Information**, Computer Physics Communication, Vol.54, (381-390), 1989.
- A. Chilingarian, G. Zazyan, **The Bootstrap Method of Determining the Coefficients of Distribution Mixture**, Pattern Recognition letters II, (781), 1990
- F. Aharonyan, A. Konopelko, A. Chilingarian, A. Plyasheshnikov, **The Multivariate Analysis of Cherenkov Images of EAS from γ -Quanta and Protons**, Nuclear Instruments and Methods, A302, (522), 1991.
- A. Chilingarian, G. Zazyan, **The Analysis of Multiparticle Production at High Energies with Renie Dimensions**, Computer Physics Communication 56, 1991.
- A. Chilingarian, **Investigation of Mass Composition and Energetic Spectrum of Cosmic Ray Protons in the Energy Ranges 1015-1017 eV according to the Data of Cosmic Ray Complex Facilities**, IL Nuovo Cimento, 14C(6), (555), 1991.
- A. Chilingarian, **Development of the Data Processing Methods in High Energy Physics. From a Data Base to a Knowledge Base**, Preprint YerPhi-1327(22), 1991.
- A. Chilingarian, H. Zazyan, **Particle Beam Experiments in Cosmic Ray Physics. Strong Interaction Parameters Determination by Statistical Pattern Recognition**, Preprint YerPhi-1345(40), 1991.

YerPhi publications on ML (3)

- A. Chilingarian, **The Mathematical Models of Neural Networks As Pattern Recognition Systems**, Preprint YerPhi-1350(45), 1991.
- F. Aharonyan, A. Chilingarian, A. Plyasheshnikov, et al., **Multivariate Correlation Analysis for the System of γ -Telescopes**, Proceedings of USSR Academy of Science, physics series, Vol. **55**, 1991.
- A. Chilingarian, G. Zazyan, **Experiments with Particle Beams in Cosmic Rays. Determining Strong Interaction Parameters by means of Pattern Recognition methods**, Nuclear Physics, 54, (128-136), 1991.
- A. Chilingarian, **Neural Net Classification of the γ and p Images Registered with Atmospheric Cherenkov Technique**, Proceedings of the 22th ICRC, OG-4.7.23 , vol.1, Dublin, Ireland, 1991.
- S. Galfayan, A. Chilingarian, **Median Estimators of Probability Density Multivariate Function**, Proceedings of the 4th Seminar on Multivariate Statistical Analysis, Tsakhkadzor, Armenia, 1991.
- A. Chilingarian, R. Shaghoyan, **Mathematical Models of Neural Networks, part 2**, Preprint YerPhi-13590(1), 1993.
- F. Aharonyan, R. Mirzoyan, A. Chilingarian et.al, **The System of Optical Cherenkov Telescopes, A New Approach to High Energy Gamma Astronomy**, Experimental Astr., **2**, (331-344), 1993.

YerPhI publications on ML (4)

- A. Chilingarian, **Neural Classification Technique for Background Rejection in High Energy Physics Experiments**, Neurocomputing, Vol. 16, (497), 1994.
- M. Cawley, A. Chilingarian, **Optimizing the Non-Linear Gamma-Ray Domain in {VHE} Gamma-Ray Astronomy using Neural-Network Classifier**, Proceedings of the 24th International Cosmic Ray Conference (ICRC), Vol. 3, (742), Rome, Italy, 1994.
- A. Chilingarian, **Detection of Weak Signals Against Background using Neural Network Classifiers**, Pattern Recognition Letters, vol. 16, (333), 1995.
- A. Chilingarian, **The Non-linear Signal Domain Selection using a New Quality Function in Neural Net Training**, Nuclear Instruments and Methods (NIM), 389A, (242), 1997.
- A. Chilingarian et al., **On the Nonparametric Classification and Regression Methods for the Multivariate {EAS} Data Analysis**, Nuclear Physics B, 52B, (237), 1997.
- KASCADE collaboration, **Estimate of the Cosmic Ray Composition by a Pattern Analysis of the Core of PeV EAS**, Proceedings of the 26th ICRC, Vol. 1, (329), Salt- Lake City, Utah, USA, 1999.
- A. Vardanyan, H. Gemmeke, W. Eppler, T. Fischer, A. Chilingarian, **The SAND/1 Neurochip as Fast "Intelligent" Trigger for the MAGIC Experiment**, Proceedings of the 2nd Irano-Armenian Workshop on Neural Networks, (107), Tehran, Iran, 1999.
- M. Roth, A. Chilingarian, A. Vardanyan, **A Nonparametric Approach for Determination of Energy Spectrum and Mass Composition of Cosmic Rays from EAS Observables**, Nuclear Phys. B, 75A, (302), 1999.
- A. Chilingaryan, N. Gevorgyan, A. Vardanyan, D. Jones and A. Szabo, **Multivariate Approach for Selecting Sets of Differentially Expressed Genes**, Math. Biosciences, Vol. 176(1), (59-69), Elsevier Science Inc. PII: S0025-5564(01)00105-5, 2002.

YerPhI publications on ML (5)

- T.Antoni, A. Chilingarian, et.al., for the **KASCADE** collaboration, **A Non- Parametric Approach to Infer the Energy Spectrum and the Mass Composition of Cosmic Rays**, Astroparticle Physics, Vol.16, (245-263), 2002.
- T.Antoni, A. Chilingarian, et al., for the **KASCADE** collaboration, **Preparation of Enriched Cosmic Ray Mass Groups with KASCADE**, Astroparticle Physics Vol.19, (715-728), 2003.
- A. Chilingarian, G. Gharagyozyan, G. Hovsepyan, S. Ghazaryan, L. Melkumyan, A. Vardanyan, **Light and Heavy Cosmic-Ray Mass Group Energy Spectra as Measured by the MAKET-ANI Detector**, The Astrophysical Journal, **603**, (L29-L32), 2004.
- A. Chilingarian, G. Hovsepyan, G. Gharagyozyan, G. Karapetyan, **On the Statistical Methods of the Signal Significance Estimation in the Detection of the Signal from the Point Sources of Cosmic Rays**, International Journal of Modern Physics A, Vol. 20, No.29, (6753-6765), 2005.
- A. Chilingarian, V.Babayan, N.Bostanjyan, G.Karapetyan, H.Martirosyan, M.Zazyan,
- **Multivariate Correlation Analysis of Transient Solar Events by the Facilities of Aragats Space Environmental Center (ASEC)**, Proceedings of 29th International Cosmic Ray Conference, Vol. 2, S.H. 3.5, (281-284), Pune, India, 2005.
- A. Konopelko, A Chilingarian and A Reimers, **Study on cosmic ray background rejection with a 30 m stand-alone IACT using non-parametric multivariate methods in a sub-100 GeV energy range**, J. Phys. G: Nucl. Part. Phys. 32, (2279 -2291), 2006.
- A. Chilingarian, G. Gharagyozyan, G. Hovsepyan, G. Karapetyan, **Statistical Methods for Signal Estimation of Point Sources of Cosmic Rays**, Astroparticle physics **25**, (269-276), 2006.