

Głębokie uczenie

Wykład 6



- Bayesowskie sieci neuronowe
- Mixture Density Networks MDN

Marcin Wolter

IFJ PAN

13 stycznia 2021



Uczenie maszynowe vs bayesowskie

Uczenie maszynowe

Ucząc funkcji $y = f(x)$ na podstawie **danych treningowych** $T = (\mathbf{x}, \mathbf{y}) = (\mathbf{x}, y)_1, (\mathbf{x}, y)_2, \dots, (\mathbf{x}, y)_N$ i **więzów** dostajemy jedną estymowaną funkcję $f(x)$

Uczenie bayesowskie

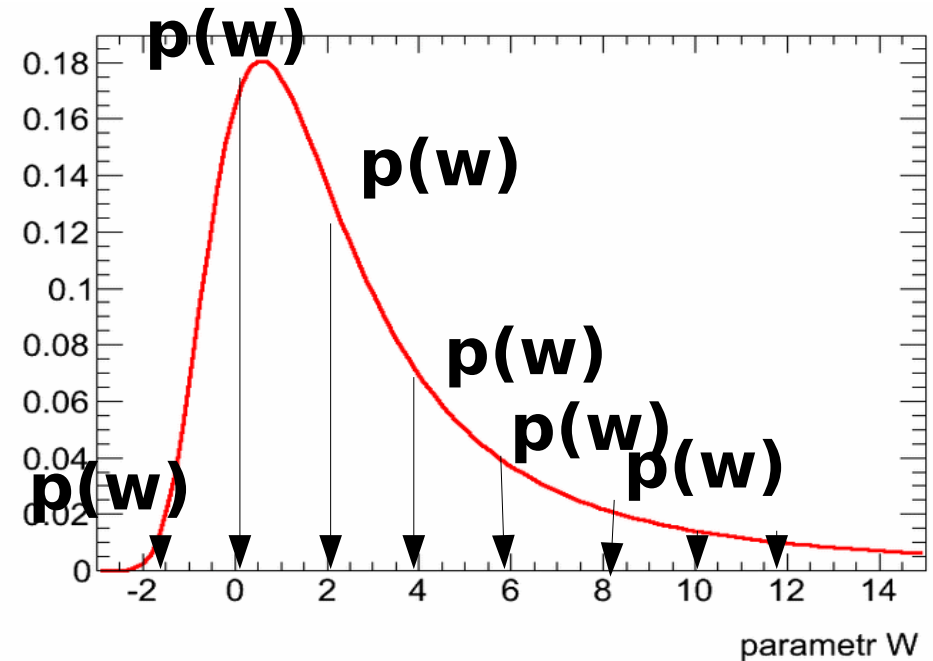

Dla każdej funkcji $f(x)$ z przestrzeni F znajdujemy prawdopodobieństwo *a posteriori* $p(f | T)$ na podstawie danych $T = (\mathbf{x}, \mathbf{y})$.

W uczeniu bayesowskim **NIE DOSTAJEMY** jednej, najlepszej funkcji aproksymującej, ale wiele funkcji ważonych ich prawdopodobieństwem.

Prawdopodobieństwo *a posteriori* – prawdopodobieństwo obliczone z użyciem wyników eksperymentu.

Zbiór treningowy $T = (\mathbf{x}, \mathbf{y})$: zbiór wektorów wejściowych \mathbf{x} i wynikowych \mathbf{y} .

Uczenie maszynowe i bayesowskie



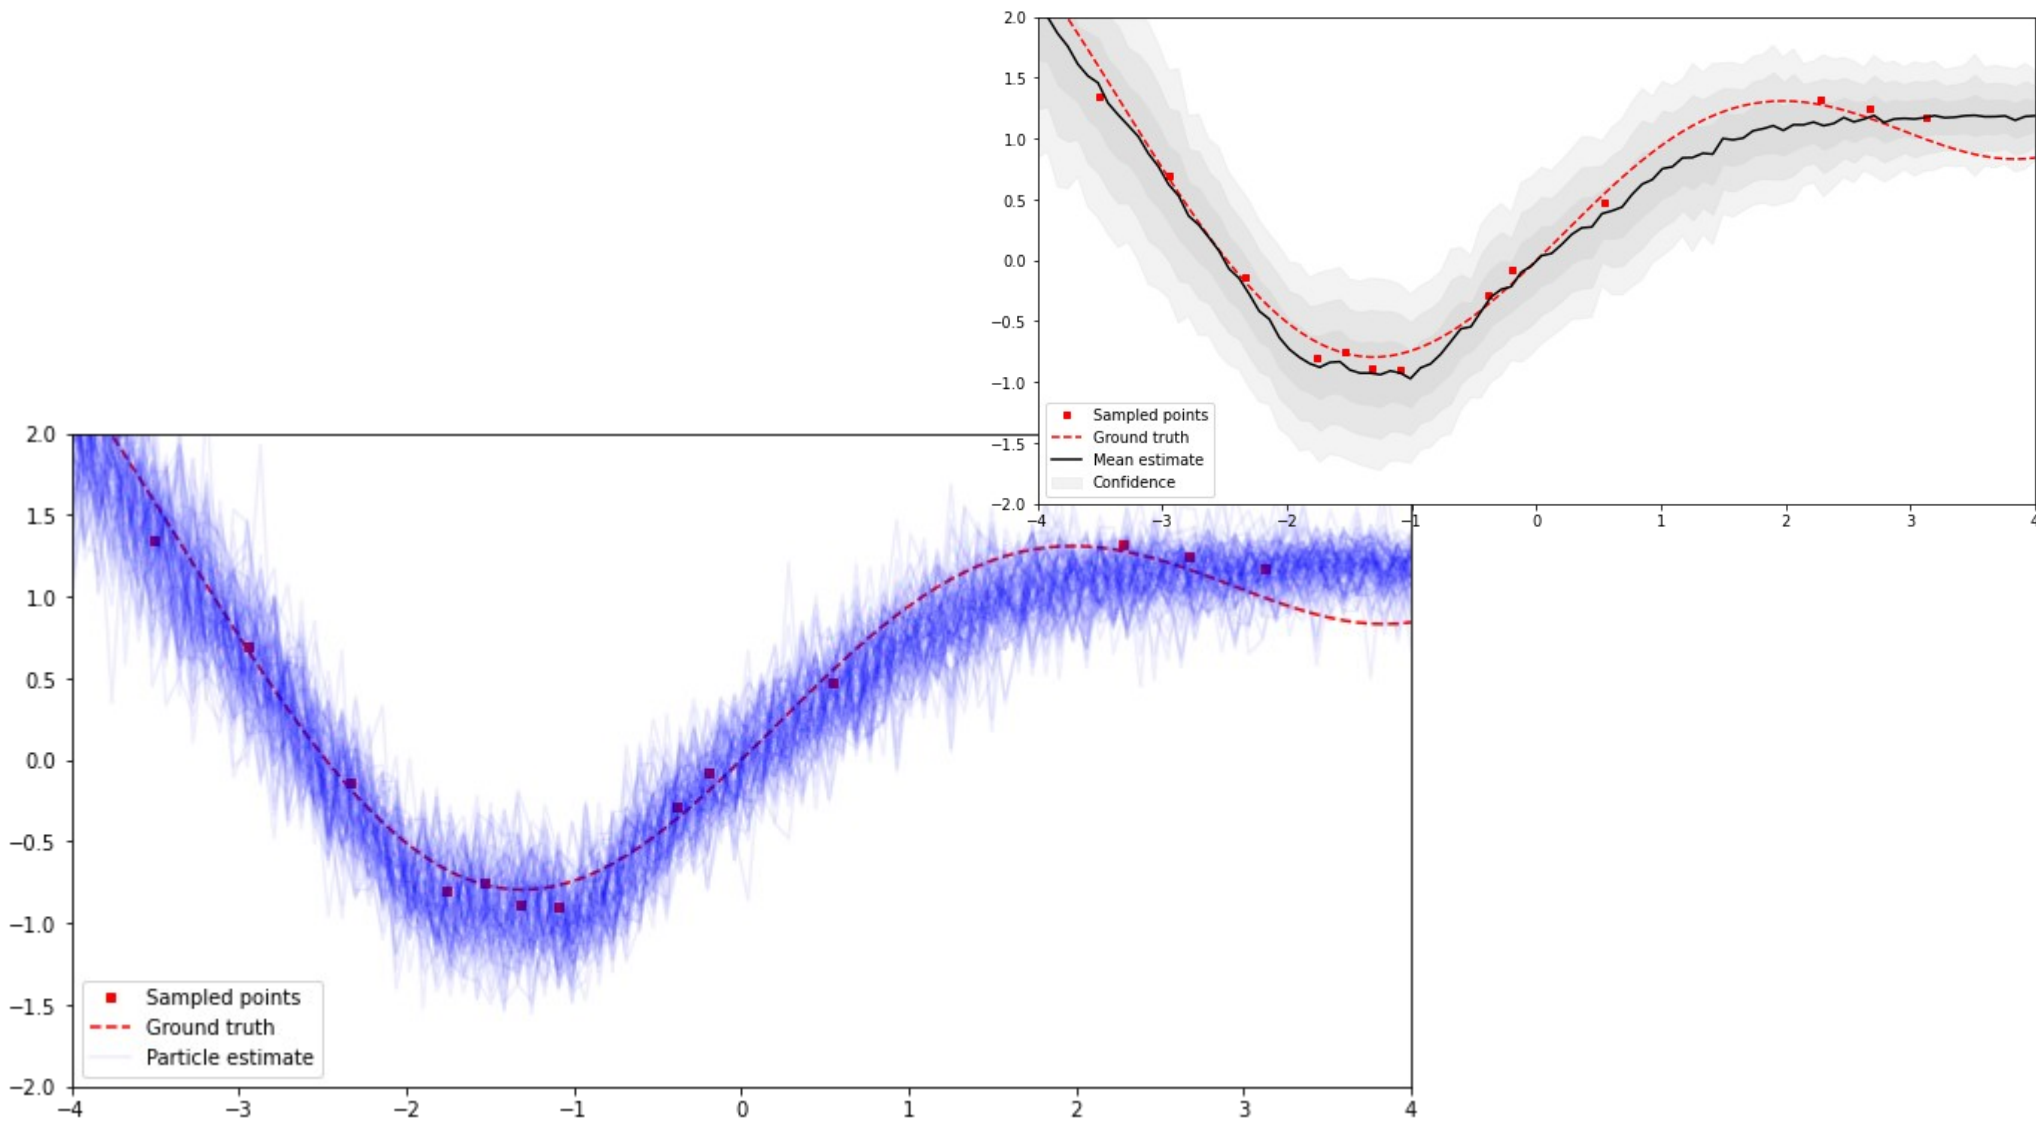
Uczenie maszynowe

Wybieramy jedną funkcję (lub wartość parametru/ów opisującego funkcję).

Uczenie bayesowskie

Każda funkcja (lub wartość parametru) posiada pewne prawdopodobieństwo (wagę).


Przykład bayesowskiej sieci neuronowej



● https://github.com/marcinwolter/DeepLearning_2020/blob/main/bnn_regression.ipynb

Mixture Density Network MDN

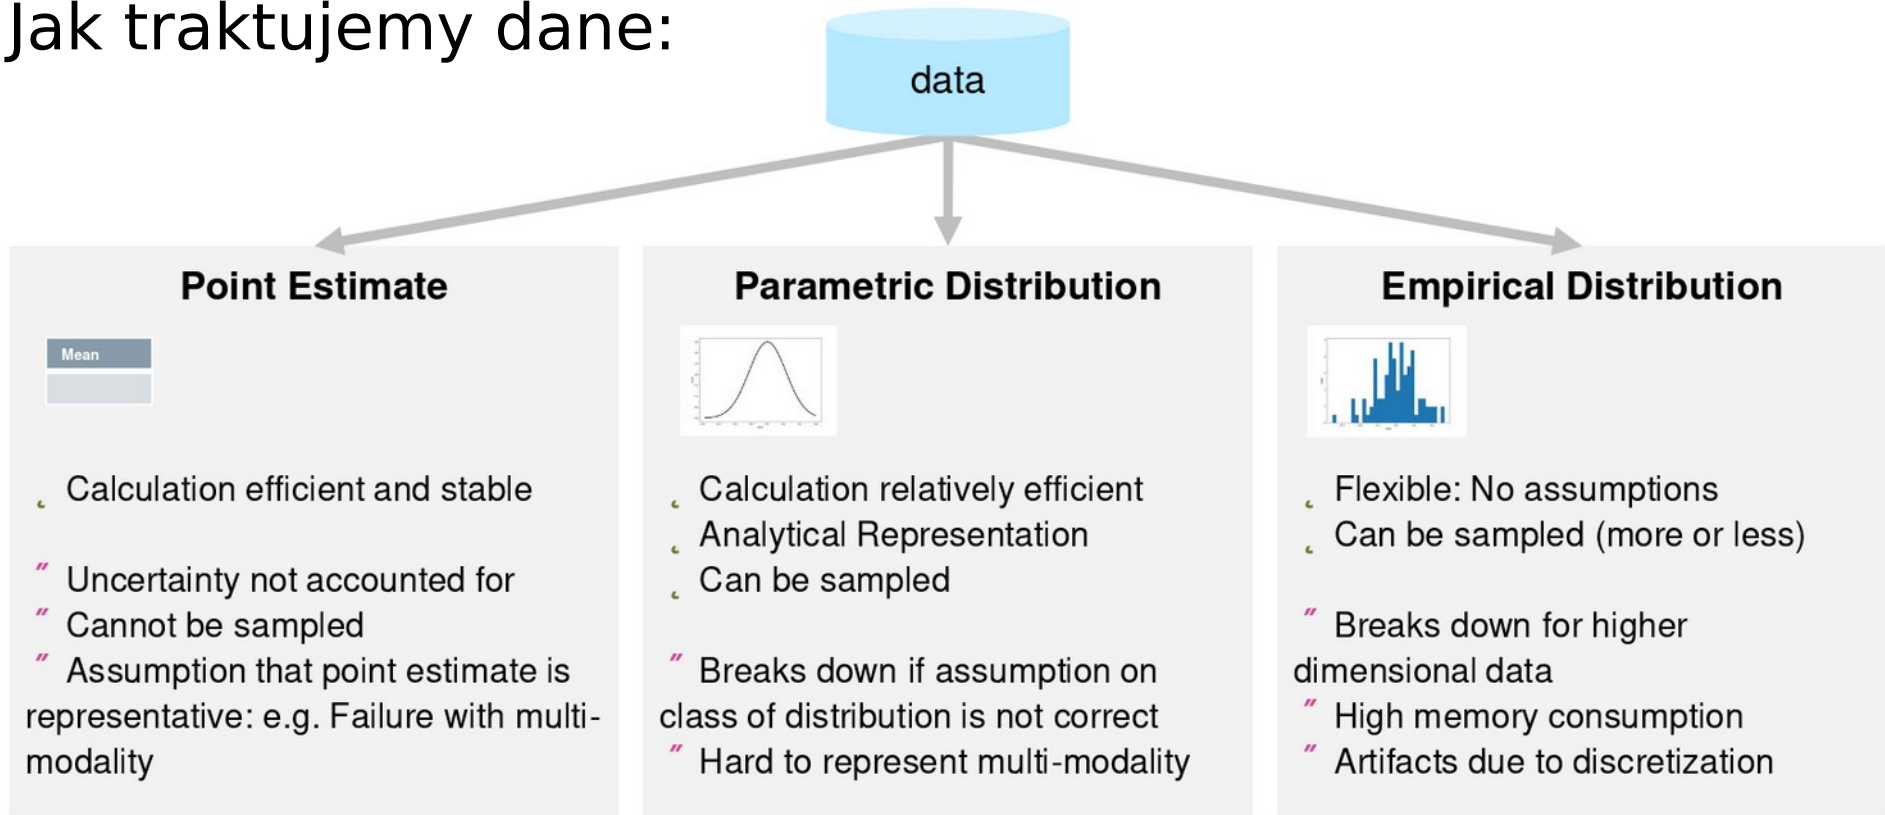
- Musieliśmy trenować bardzo wiele... Zabiera to dużo czasu.
- Może dałoby się to zrobić bardziej wydajnie?
- Idea:
 - Stwórzmy sieć, która zwraca sparametryzowane rozkłady prawdopodobieństwa



Nazywa się Mixture Density Network (MDN).
Rozkład prawdopodobieństwa jest sparametryzowany przez kilka rozkładów Gaussa.

Mixture Density Network (MDN)

Jak traktujeme dane:



Classic Neural Network


Mixture Density Neural Network

Bayesian Networks

Mixture Density Network (MDN)

- MDN – przydatny formalizm aproksymujący rozkład prawdopodobieństwa.
- Rozkład prawdopodobieństwa warunkowego *a posteriori* $p(y|x)$ jest aproksymowany jako suma kilku rozkładów Gaussa, gdzie rozkłady te są sparametryzowane przez parametry będące funkcją danych wejściowych x .


Regression:




Regular network - OK

Ciekawa prezentacja:

http://www.dbs.ifi.lmu.de/Lehre/DLAI/WS18-19/script/06_uncertain.pdf

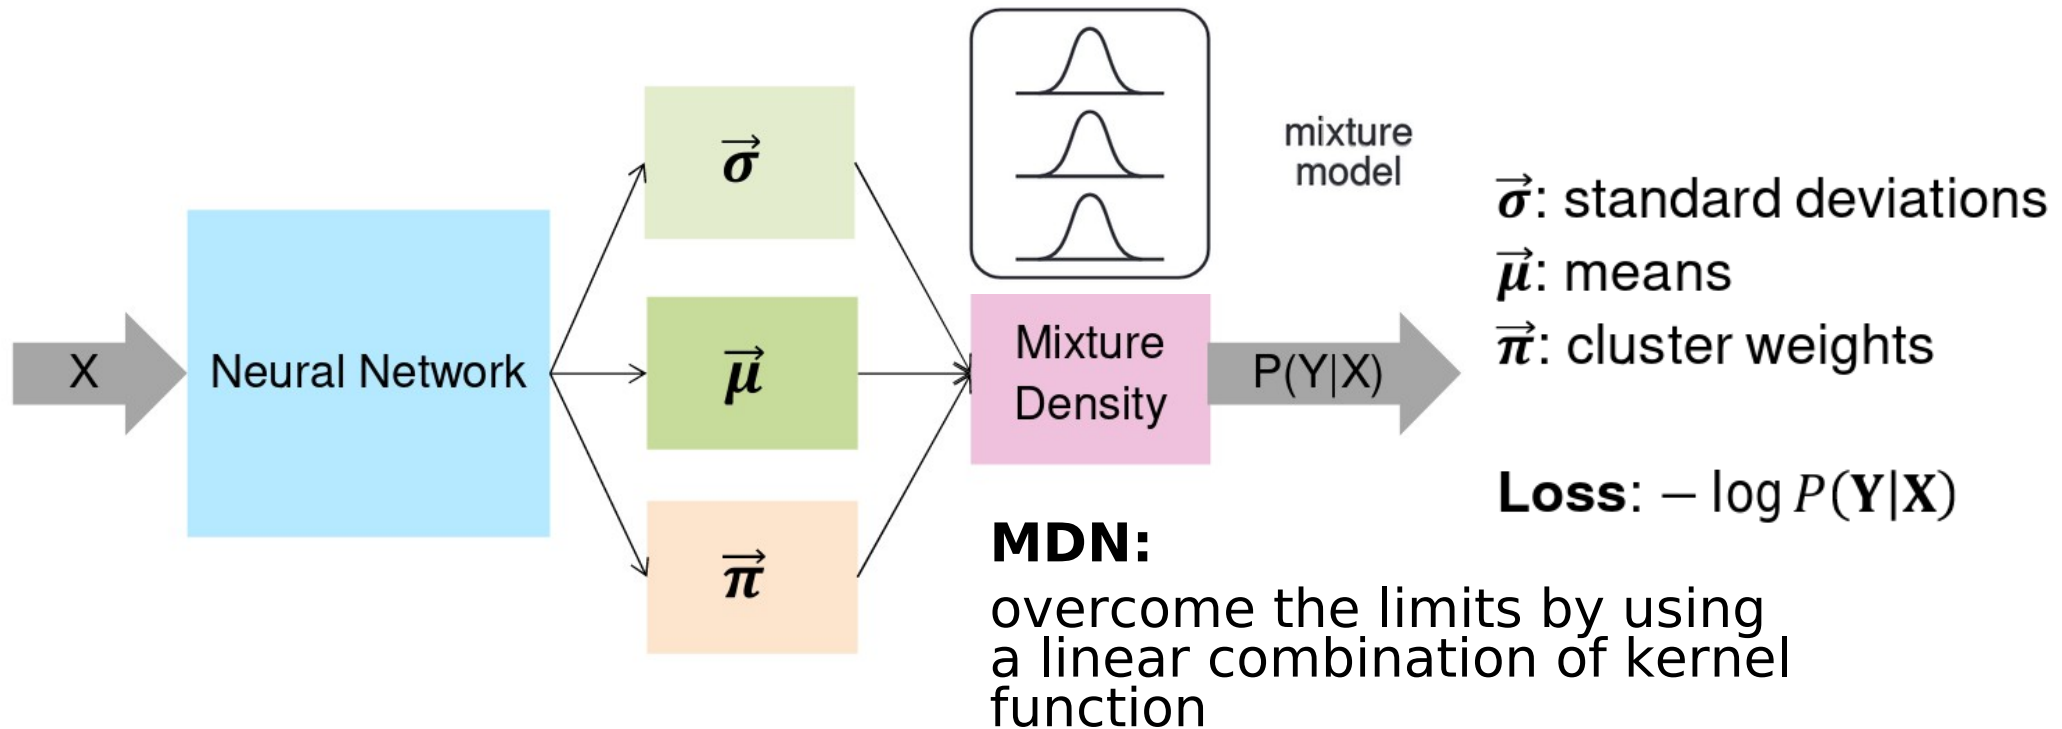


Regular network -
problems



MDN sampling - OK

Mixture Density Network (MDN)



MDN zwraca nie tylko maksimum rozkładu prawdopodobieństwa (jak zwyczajna sieć neuronowa), ale całe rozkłady prawdopodobieństwa (czyli też błędy).

Reference: Bishop, Christopher M. *Mixture density networks*. Technical Report NCRG/4288, Aston University, Birmingham, UK, 1994

<http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.120.5685&rep=rep1&type=pdf>



Działający przykład MDN

Przykład z:

<https://github.com/cpmpercussion/keras-mdn-layer>

Na dole strony jest instrukcja, jak używać MDN (bardzo prosto).

Przykład dla Google Colaboratory:

https://github.com/marcinwolter/DeepLearning_2020/blob/main/MDN_1D_sine_prediction.ipynb


Przykład MDM

- ATLAS cluster position calculation




Currently uses a three-step process

1. Number Network: Determine the **number of particles** in this hit
2. Position Network: Determine the **x-y position** of each particle
3. Error Network: Estimate the **error in x and y** for each particle

MDN: Feedforward network + Gaussian kernel(s)



ATLAS studies of Elham E Khoda:
https://indico.cern.ch/event/795039/contributions/3432383/attachments/1856640/3049881/Machine_Learning_in_CTIDE_1.pdf

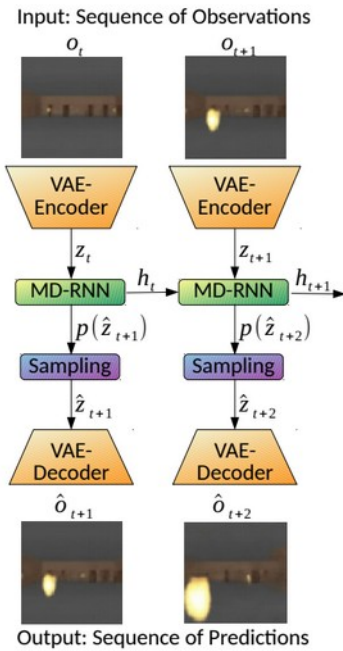
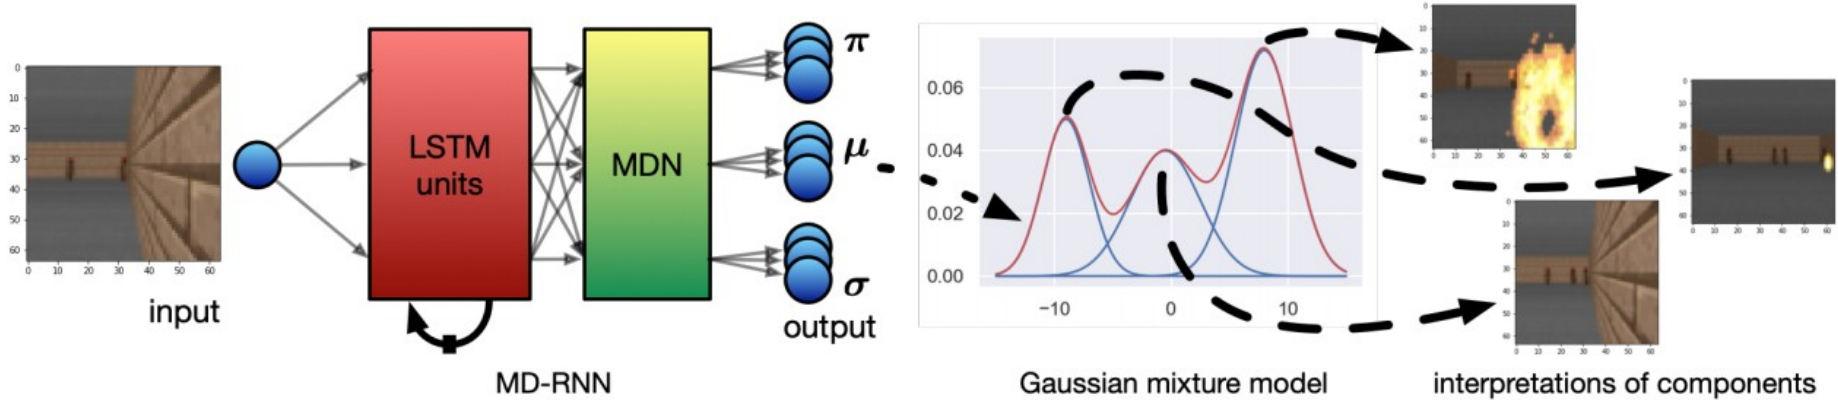


Przykład zastosowania



How do Mixture Density RNNs Predict the Future? Kai O. Ellefsen, Charles P. Martin, Jim Torresen
<https://arxiv.org/pdf/1901.07859.pdf>

Problem: przewidywanie przyszłości w grze komputerowej.



Model zwraca serię przewidywań bazujących na poprzednich klatkach. Do każdego przewidywania podaje też błąd.


Figure 2. World model predicting future frames by combining a variational autoencoder and an MD-RNN. We follow the architecture suggested in (Ha & Schmidhuber, 2018).

Przykład: klasyfikacja ręcznie pisanych cyfr MNIST

- Szkielet programu:


https://github.com/marcinwolter/DeepLearning_2020/blob/main/simple_mnist_mdn_skeleton.ipynb

- Trenujemy sieć na cyfrach, ale potem testujemy na MNIST fashion:




Nic nie wiemy o błędzie klasyfikatora!


Używamy MDN




NN output



True



NN output



True

Mixed Density Networks MDN

- Dość leciwy pomysł (lata 90-te)
- Ale bardzo przydatny:
zamiast jednej wartości
dostajemy rozkład
prawdopodobieństwa!

Choi, Sungjoon, et al. "Uncertainty-aware learning from demonstration using mixture density networks with sampling-free variance modeling." 2018 IEEE International Conference on Robotics and Automation (ICRA). IEEE, 2018.

<https://arxiv.org/pdf/1709.02249.pdf>

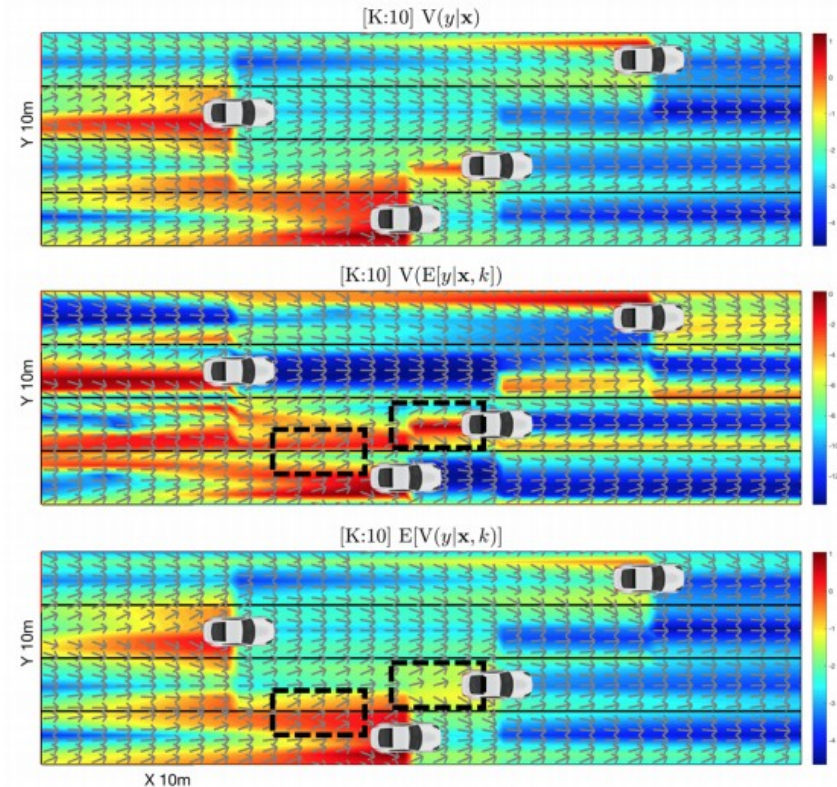




Fig. 5: Different uncertainty measures on tracks.



More scientific - Pattern Recognition in High Energy Physics



Seeding

Track Building


Track Fitting

- **Track seeding** – finding the seeds (initial sets of hits) from which the track starts
- **Track building** \equiv pattern recognition HEP jargon
 - Creating a 2- and 3-dimensional lines and assigning to them all the hits within a certain window
 - Fitted frequently with “robust fit”
- **Track fitting** – final fitting of the track parameters (usually a Kalman filter used for tracking)

Usually this method works fine, is robust and efficient!



So, where is the problem?



CMS experiment simulation
J.-R. Vlimant, *Machine Learning for Charged Particle Tracking*, MIT, 2018


- The time needed to process one event grows quickly (worse than quadratic) with luminosity (number of collisions).
- Huge part of CPU consumption is the track finding.

Deep Neural Network (DNN)?

- Fast, parallel, in principle does pattern recognition “at once”, without looping over hits.
- Also experiments with lower occupancy might profit from DNN’s – higher precision and efficiency.
- There is a HEPTrkx group working on tracking for HEP experiments:
<https://heptrkx.github.io/>

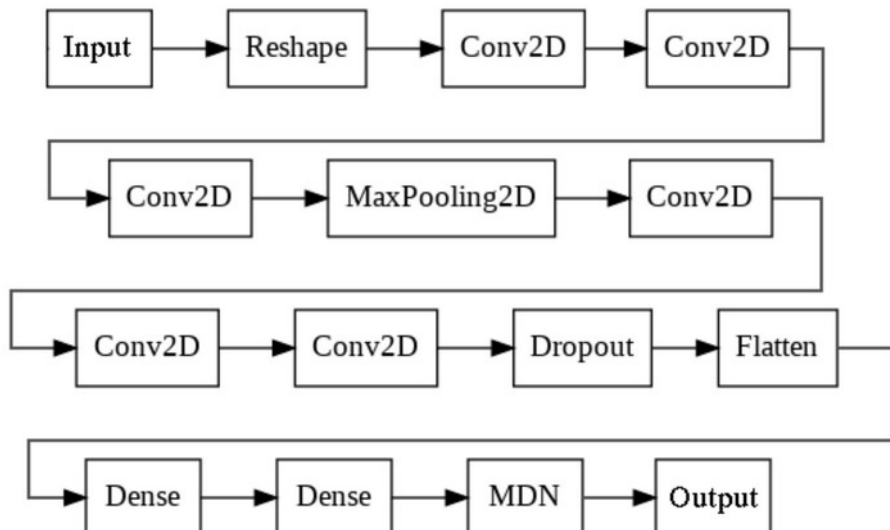
Tracking in 2D toy model

- CNN returns track parameters (regression)
- What about many tracks?
 - Solution: add **Mixture Density Network(MDN)** layer to process many tracks.
 - Straight tracks – described by two parameters. Each parameter has associated MDN Gaussian
 - If a number of tracks lower than expected some MDN outputs have very low amplitude.
 - **Important** - we are getting errors of track parameters

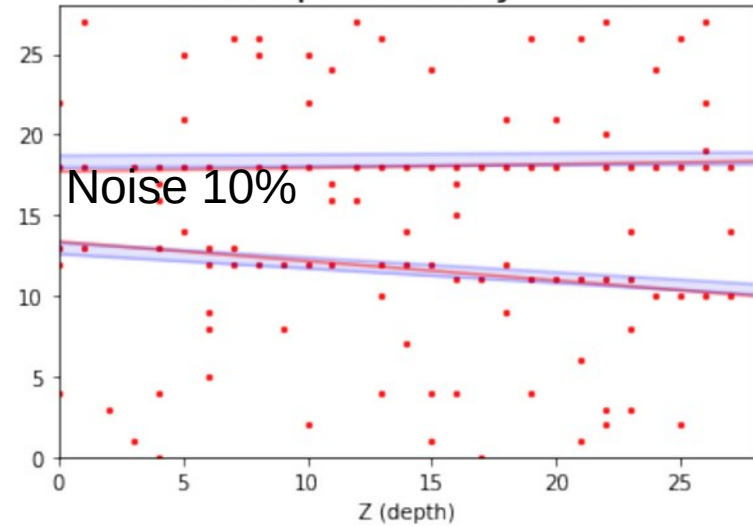


Track described by two interception parameters b_1 and b_2 .


Mixed Density Network




Noise probability = 0.1



Noise probability = 0.2



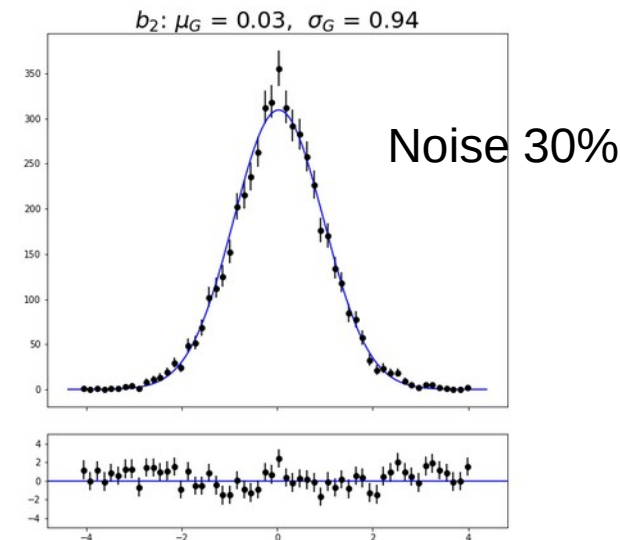

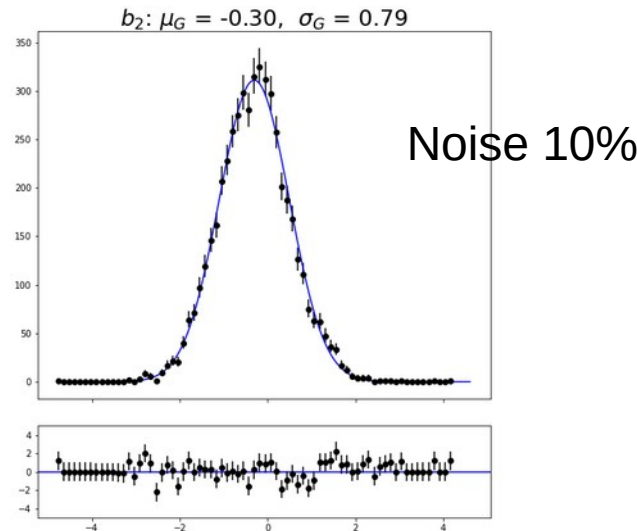

Noise probability = 0.3



Designed by **Karol Białas** and **Mateusz Słysz** summer students at IFJ:

https://github.com/marcinwolter/MachineLearnin2019/blob/master/dnn_tracking_2D_mdn_multimod.ipynb

MDN Tracking – error estimation



Pull plots have a width not far from 1.

If a random variable x is generated repeatedly with a Gaussian than the pull distribution:

$$g = \frac{x - \mu}{\sigma}$$

will be distributed as a standard Gaussian with mean zero and unit width.