

Využití neuronových sítí pro odhad dynamických veličin

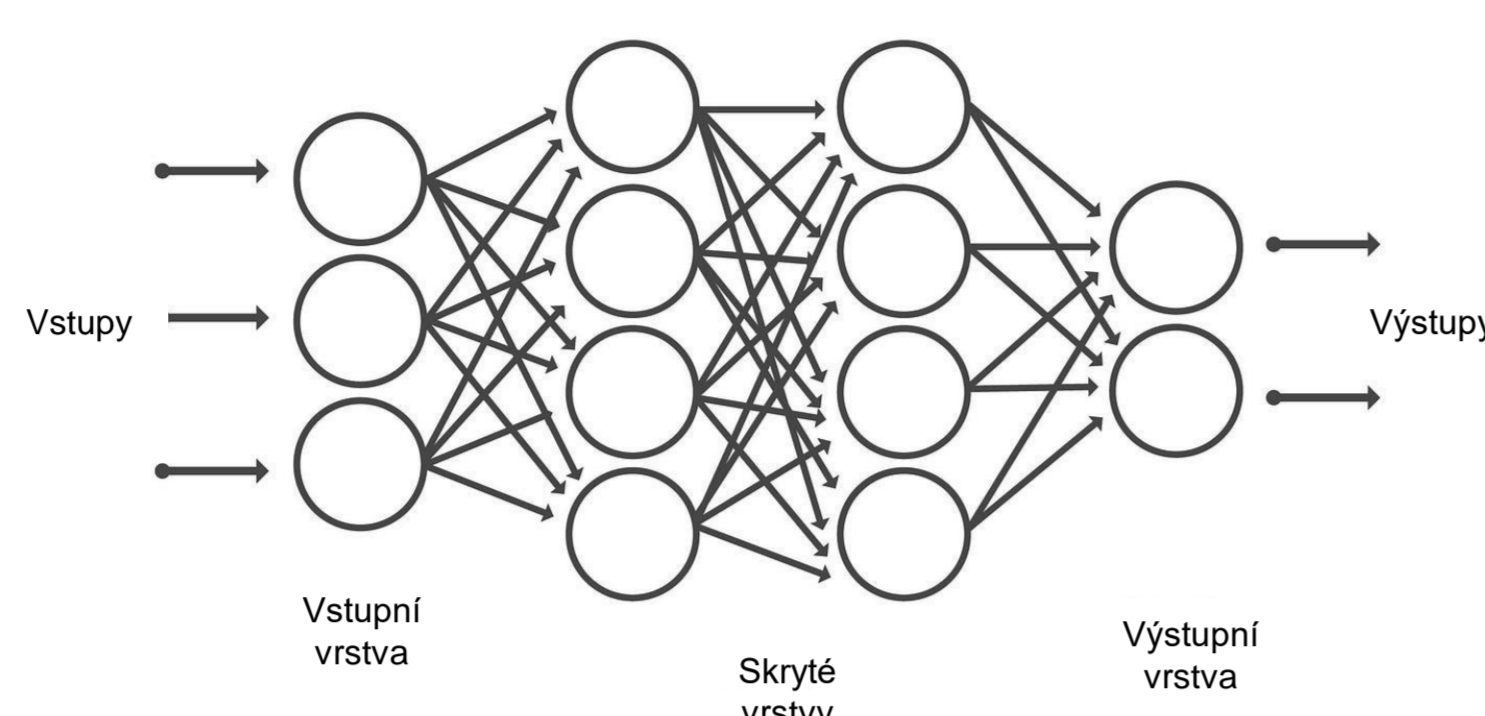
Martin Dufek

Ústav automobilního a dopravního inženýrství

CÍLE PRÁCE




- Návrh a sestavení neuronové sítě pro predikci dynamických veličin
- Ověření využití neuronových sítí k predikci dynamických veličin v praxi



NEURONOVÉ SÍTĚ


- Obrovský potenciál ve všech odvětvích
- Inspirovány biologickými nervovými systémy
- Sekvenční data
- Konvoluční, dopředné, rekurentní (regresní typ úlohy)



ZPRACOVÁNÍ NAMĚŘENÝCH DAT



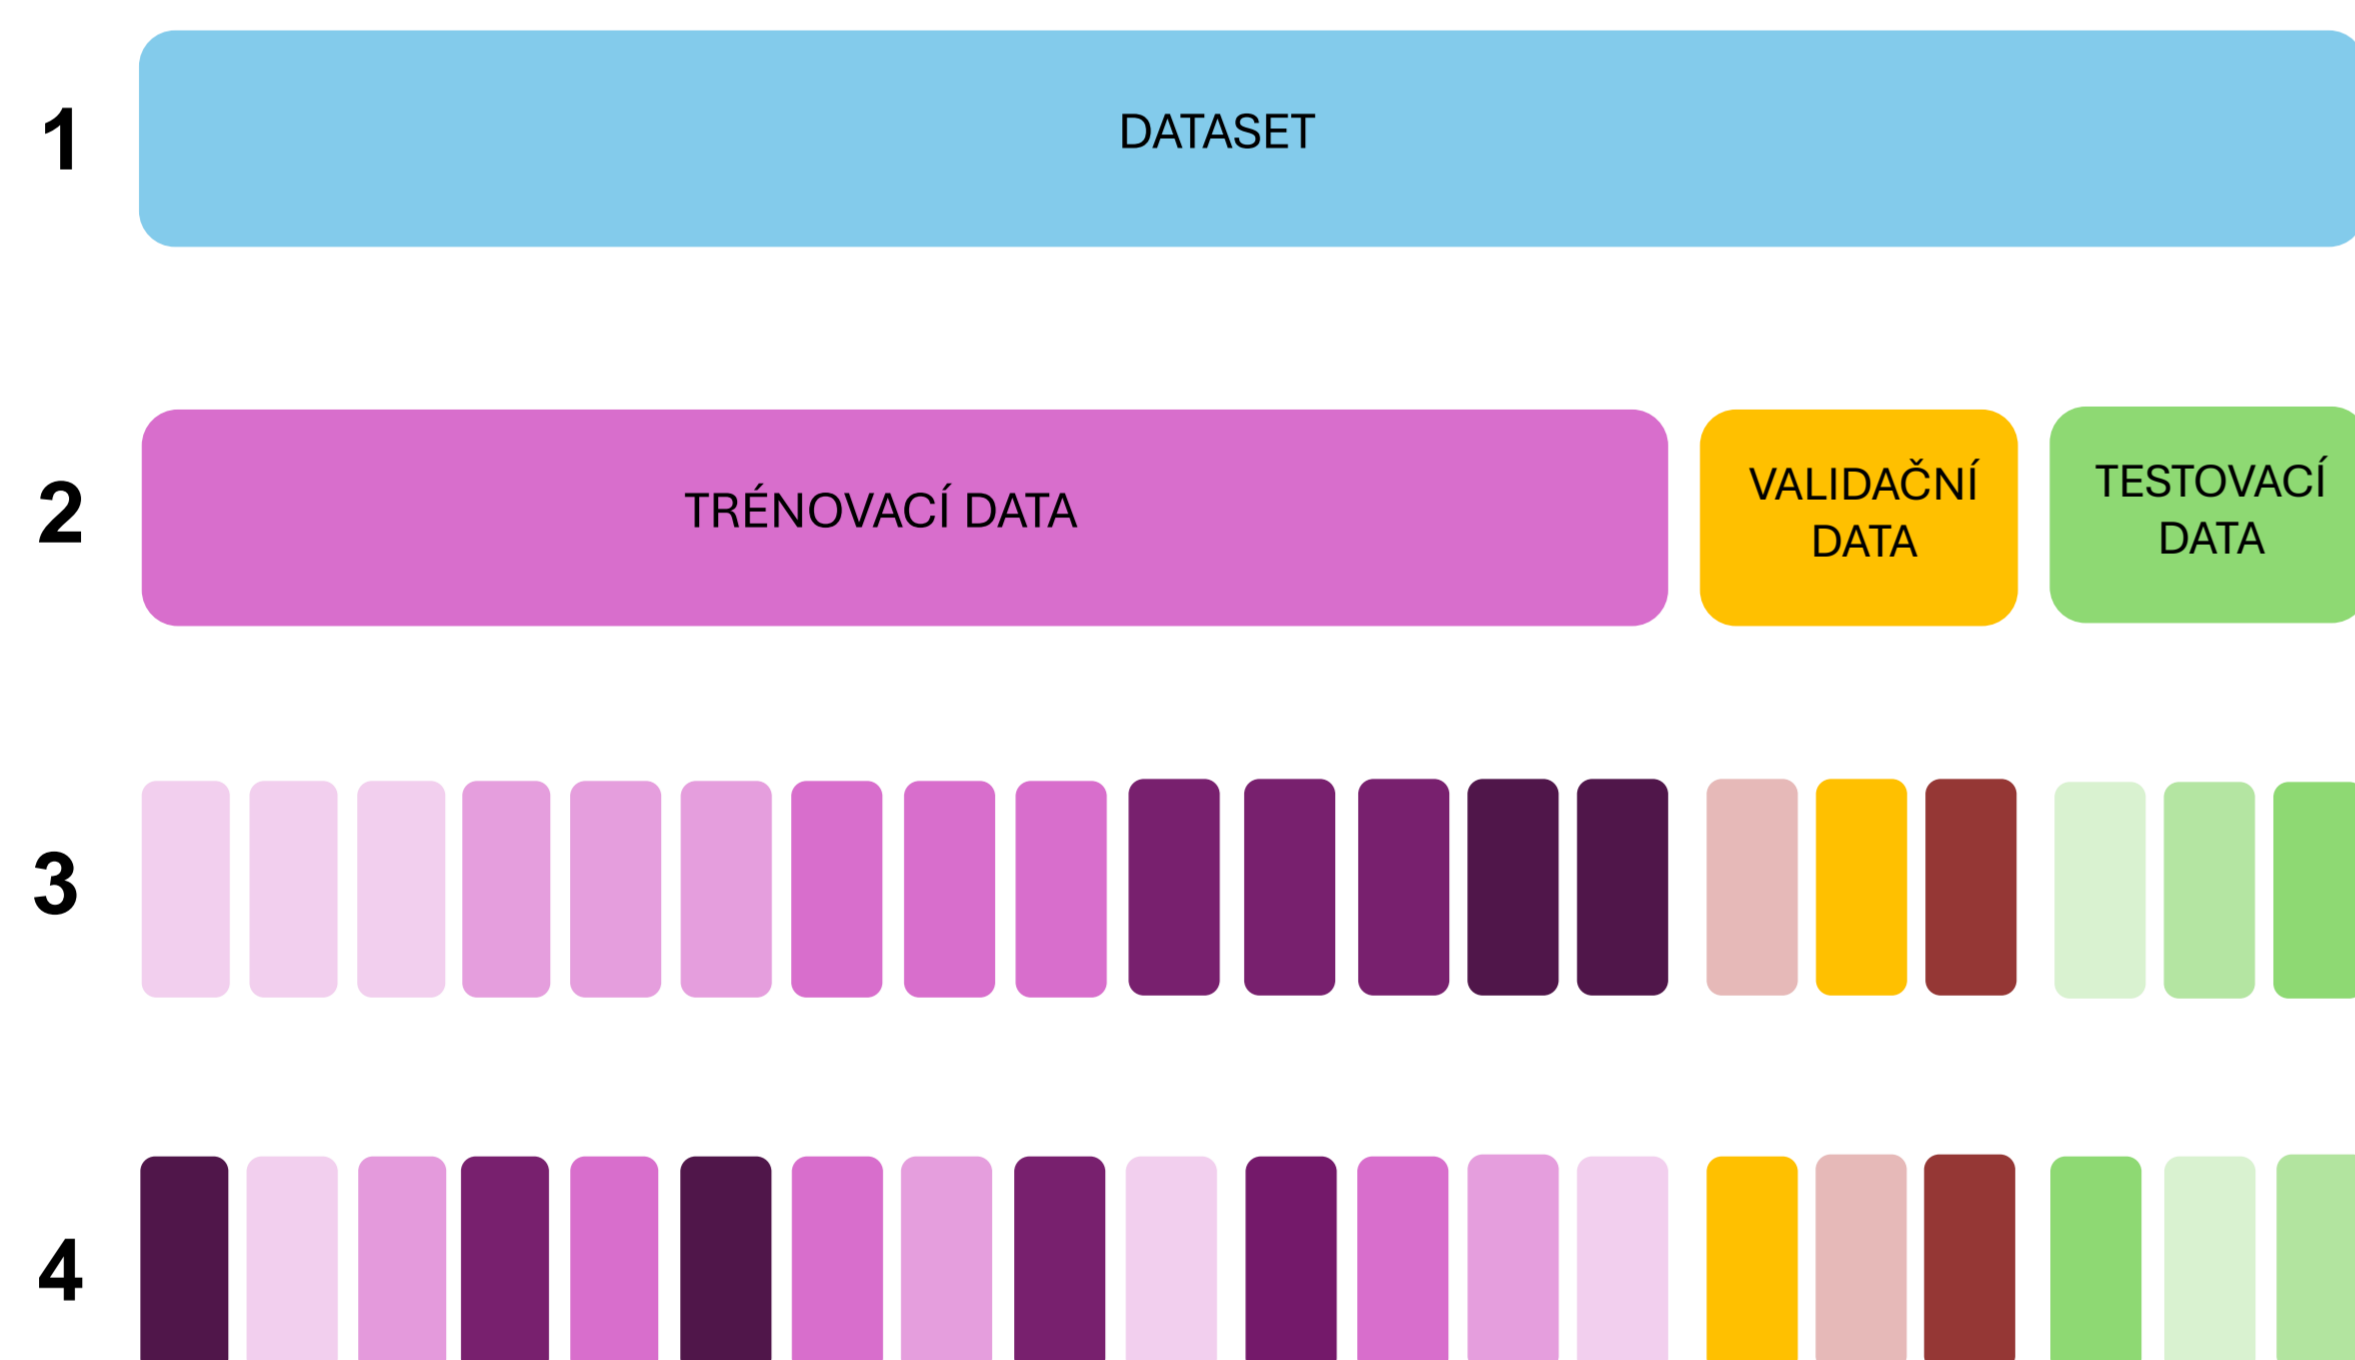
- 45minutová jízda vozidla
- 47 různých proměnných
- Vzorkovací frekvence 100 Hz
- 272 389 hodnot
- Ořezání dat
- Směrová úchylka, podélné síly na kolech
- Znečištěnost, poškozenost, chybějící hodnoty
- Filtrování dat
- Rozdělení dat
 - Trénovací (70 %)
 - Validační (15 %)
 - Testovací (15 %)



ROZDĚLENÍ DAT NA SEKVENCE



- Vyžaduje rekurentní neuronová síť
- Délka sekvence dle sledovaného jevu
- n datových kroků v sekvenci
- Generalizace sítě



OVĚŘENÍ ZÁVISLOSTI PŘESNOSTI PREDIKCE SÍTĚ NA ZVOLENÝCH VSTUPNÍCH VELIČINÁCH



- Hodnocení – RMSE
- Možné zlepšení i zhoršení predikce
- Postupné odečtení vstupů
- Celkem 9 nastavení
- Pro každé nastavení 5 trénování
- Nižší hodnocení = lepší
- Nejlepší výsledek – vX , vY , vZ

| Vstupní parametry | 1. test | 1. validace | 2. test | 2. validace | 3. test | 3. validace | 4. test | 4. validace | 5. test | 5. validace | Test průměr | Validace průměr |
|---------------------------|---------|-------------|---------|-------------|---------|-------------|---------|-------------|---------|-------------|-------------|-----------------|
| všechny | 0,014 | 0,061 | 0,011 | 0,059 | 0,023 | 0,081 | 0,014 | 0,044 | 0,015 | 0,065 | 0,0154 | 0,0618 |
| všechny - aX, aY, aZ | 0,016 | 0,058 | 0,016 | 0,049 | 0,012 | 0,062 | 0,011 | 0,055 | 0,014 | 0,057 | 0,0138 | 0,0562 |
| všechny - pitch | 0,015 | 0,080 | 0,020 | 0,056 | 0,022 | 0,090 | 0,014 | 0,042 | 0,014 | 0,055 | 0,0169 | 0,0649 |
| všechny - roll | 0,016 | 0,053 | 0,011 | 0,062 | 0,015 | 0,072 | 0,014 | 0,064 | 0,013 | 0,057 | 0,0138 | 0,0614 |
| všechny - wX, wY, wZ | 0,017 | 0,034 | 0,015 | 0,027 | 0,009 | 0,027 | 0,010 | 0,028 | 0,014 | 0,039 | 0,0129 | 0,0310 |
| všechny - vX, vY, vZ | 0,092 | 0,161 | 0,093 | 0,154 | 0,085 | 0,146 | 0,179 | 0,191 | 0,091 | 0,187 | 0,1080 | 0,1679 |
| všechny + dmp | 0,084 | 0,177 | 0,086 | 0,385 | 0,073 | 0,261 | 0,084 | 0,219 | 0,071 | 0,171 | 0,0795 | 0,2385 |
| vX, vY, vZ + pitch + roll | 0,009 | 0,029 | 0,011 | 0,031 | 0,010 | 0,038 | 0,008 | 0,028 | 0,010 | 0,036 | 0,0097 | 0,0324 |
| vX, vY, vZ | 0,010 | 0,018 | 0,012 | 0,040 | 0,013 | 0,025 | 0,008 | 0,018 | 0,010 | 0,025 | 0,0104 | 0,0252 |


VÝSLEDNÁ NEURONOVÁ SÍŤ – SMĚROVÁ ÚCHYLKA



| Hyperparametr | Hodnota |
|---------------------|-------------|
| SolverName | adam |
| MaxEpochs | 1000 |
| GradientThreshold | 1 |
| Shuffle | every epoch |
| InitialLearnRate | 0,001 |
| LearnRateDropPeriod | 100 |
| LearnRateDropFactor | 1 |
| L2Regularization | 0,001 |
| ValidationFrequency | 50 |

- Jednoduchá architektura
- 250 neuronů
- Sekvence – 1000 jednotek
- 3 vstupní veličiny
 - vX , vY , vZ
- 1 výstupní veličina
 - směrová úchylka

ARCHITEKTURA NEURONOVÉ SÍTĚ



ZÁVĚR



- Směrová úchylka
 - Průměrná hodnota 0,43°
 - RMSE 0,08
 - MAE 0,0099 \approx 2 %
- Méně vstupních veličin
- Využitelnost sítí v praxi
- Nahrazení drahých měření

