

## Introdução

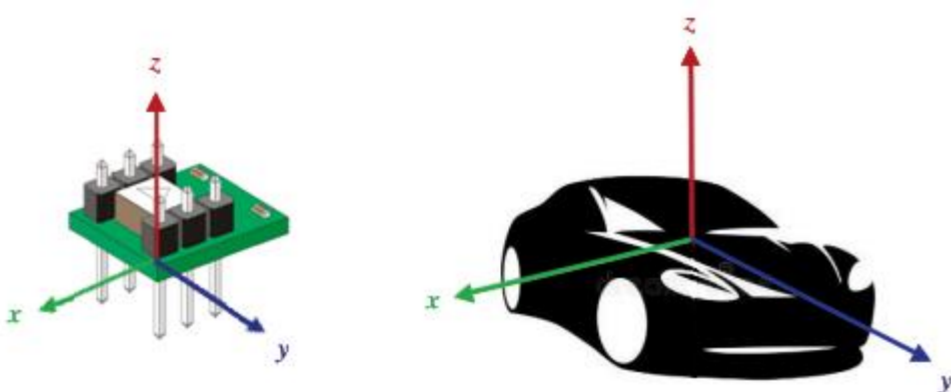
Os sistemas de transporte se estabeleceram ao longo da história como um dos principais condicionantes ao desenvolvimento humano. Com o avanço das tecnologias computacionais, surgiram os Sistemas de Transporte Inteligentes (STI), nos quais sensores são empregados na infraestrutura de trânsito e seus participantes, de forma a gerar dados situacionais para auxiliar a tomada de decisão. Neste contexto, diversas tecnologias foram desenvolvidas, dentre intrusivas e não-intrusivas, ativas e passivas. Dentre as tecnologias não-intrusivas e passivas, existem as baseadas em vibração, realizadas através de sensores inerciais, as quais podem gerar percepção veicular de forma segura, não poluente e de baixo custo.

A aplicação de sensores inerciais embarcados em veículos resulta na produção de sinais unidimensionais que podem ser utilizados na geração dos mais diversos padrões de percepção veicular de ambiente e de propriocepção veicular. Neste trabalho, foi realizada amostragem e processamento destes sinais, empregando-os junto de uma abordagem de Deep Learning para classificar a composição da superfície de pista sobre a qual o veículo trafega.

## Materiais e Métodos

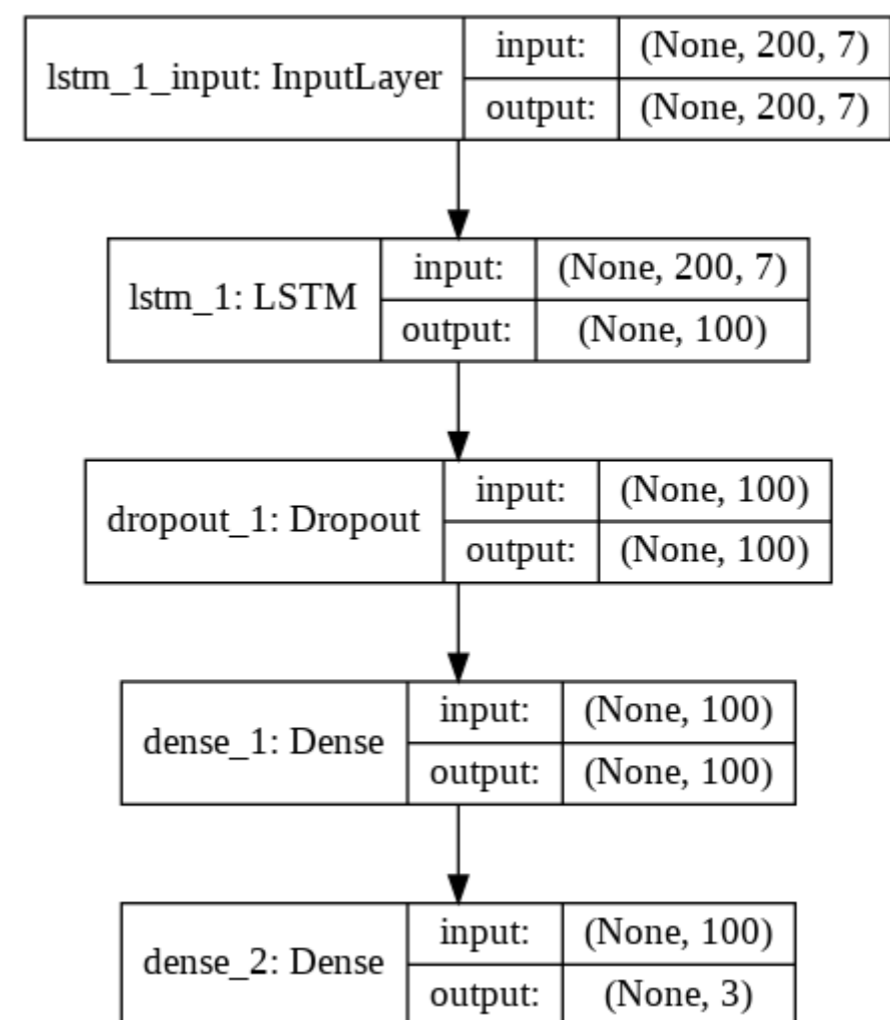
Os sensores inerciais constituem dispositivos que produzem sinais através do princípio da inércia. Estes sensores compreendem acelerômetros e giroscópios, os quais medem respectivamente a força de aceleração e a taxa de rotação aplicadas nos três eixos físicos, conforme ilustra a Figura 1. Além dos dados dos sensores inerciais, também foi utilizado um módulo GPS para medição da velocidade veicular longitudinal.

Figura 1 – Eixos de medição.



Sendo assim, foram utilizadas 7 variáveis de entrada para o modelo, sendo a aceleração (X, Y, Z) a taxa de rotação (X, Y, Z) e a velocidade. Como saída do modelo, espera-se a classificação da superfície de pista em asfalto, paralelepípedo ou terra. O modelo desenvolvido e ilustrado na Figura 2 utiliza de camadas recorrentes do tipo LSTM, Dense e Dropout. Para formação da saída, foram considerados 200 estados anteriores. Dois datasets foram utilizados, um para treinamento e outro para validação, ambos com aproximadamente 11 mil amostras cada.


Figura 2 – Modelo de Rede Neural Profunda.



## Resultados

Após o treinamento e testes com o dataset amostrado, a rede atingiu a acurácia de 94%, com MSE de 0.415. A Figura 3 ilustra os resultados obtidos.

Figura 3 – Resultado das Classificações.



## Considerações Finais

Neste trabalho desenvolveu-se um modelo de rede neural profunda pra classificar sinais de sensores inerciais de acordo com o tipo de superfície da via. O modelo resultante evidencia a capacidade da técnica de reconhecer e classificar corretamente os padrões com erro baixo e bom valor de acurácia, podendo ser empregado nos mais variados domínios de STIs, tais como sistemas colaborativos de *mobile crowdsensing*, veículos autônomos e sistemas avançados de assistência ao motorista.