

--- Aulas do Prof Emilio em PSI3471 da #1 (em 02/março) à #13 (em 29/abril) ---

Plano aproximado de temáticas aula a aula / semana a semana – versão de 01 de março

(atividades com entregas simples aproximadamente semanais ocorrerão durante as aulas)

#1 (02/março – 2^{af}) Conceitos em regressão linear e não linear. Regressão univariada e Regressão multivariada; Contrastes com técnica mais simples já conhecida: a regressão linear univariada (reta média). Diferenças principais entre 1) a Regressão e 2) o Reconhecimento / Detecção / Identificação de Padrões Multivariados. Conceitos em Reconhecimento / Detecção / Identificação de Padrões. Entendendo primeiro as ferramentas de modelagem mais simples: as ferramentas lineares multivariadas ... elementos matemáticos em regressão linear multivariada e em discriminadores lineares multivariados. Dados empíricos para calibração de parâmetros em regressores e em discriminadores; o aprendizado supervisionado.

#2 (04/março – 4^{af}) Neurônios biológicos como base para os neurônios artificiais; equações e propriedades matemáticas do neurônio artificial isolado; relação do neurônio isolado com os regressores e com os discriminadores lineares multivariados.

#3 (09/março – 2^{af}) Foco da semana: Redes de Neurônios Artificiais (RNAs), concatenando múltiplos neurônios; arquiteturas neurais diversas; arquiteturas MLP – Multi Layer Perceptron; Relação de RNAs com a implementação de regressores e reconhedores **NÃO LINEARES MULTIVARIADOS**. O ensaio computacional de redes neurais – ambientes simples como o MBP – Multiple Back Propagation – e ambientes mais complexos alternativos, de sua escolha.

#4 (11/março – 4^{af}) ... Grafos da computação em redes neurais do tipo MLP; notação matemática para pesos sinápticos, variáveis de entrada, saída e variáveis intermediárias no MBP; exemplares empíricos / observações empíricas para o treinamento supervisionado em MLPs; aprendizado com base na propagação reversa do erro (EBP – Error Back Propagation).

#5 (16/março – 2^{af}) Foco da semana: aprendizado da Rede Neural MLP – O Gradiente descendente e a otimização de pesos sinápticos com base no conjunto de treino e EBP; dedução das fórmulas do EBP, em sala de aula em conjunto com os alunos: trabalho focado num peso sináptico específico da rede, escolhido pelo professor para máxima complexidade da dedução.

#6 (18/março – 4^{af}) ... Discussão da extensão simples das deduções do EBP para demais pesos sinápticos; redundâncias nos cálculos dos diversos pesos da rede neural e otimização do esforço computacional. Regra “Delta” de aprendizado de Widrow, para neurônio isolado; Aprendizado por EBP recursivo, camada a camada.

#7 (23/março – 2^{af}) Foco da semana: Reconhedores – Circuitos lógicos genéricos e suas implementações através de computação neural; relação com discriminadores. Construindo reconhedores de padrões com fronteiras de separação genéricas: separadores lineares; bancos de separadores lineares como aproximadores efetivos de fronteiras genéricas.

#8 (25/março – 4^{af}) ... Técnicas de medida de qualidade em reconhedores de padrões: matriz de confusão, conceitos de falsos positivo e negativo, especificidade e sensibilidade. Curvas ROC.

#9 (30/março – 2^{af}) Foco da semana: Regressores - Casos simples de aproximação de funções univariadas. Teorema de Cybenko: o MLP como aproximador universal de funções multivariadas; implicações práticas do teorema para a implementação de regressores e reconhedores de padrões não lineares multivariados genéricos.

#10 (01/abril – 4^{af}) ... Medidas de qualidade diversificadas para regressores multivariados (distintas do erro quadrático médio); Flutuação do desempenho do modelo com as particulares amostras de treino e de teste e técnicas de reamostragem; técnica de validação cruzada, k-fold cross validation e leave one out. Sobreajuste / sobreaprendizado / perda de generalização em regressão polinomial e em redes neurais; limitação do número de nós neurais para evitar o sobreajuste e otimizar a generalização da rede neural; partição do volume de observações em conjuntos de treino, validação e teste.

06 e 08 de abril: Semana Santa – não há aula

#11 (13/abril – 2^{af}) Soluções em reconhecimento e em regressão empregando dois estágios: primeiro estágio para extração de características / extração de medidas e para a redução de dimensionalidade + segundo estágio MLP como reconhedor / regressor genérico; técnicas diversas de extração de características em projetos concretos. Extensões de análise harmônica (Fourier) para a extração de características; conceitos básicos em análise tempo-frequência. PCA - Análise de Componentes Principais como extrator de características.

#12 (15/abril – 4^{af}) Aprofundando a conexão dos temas que aprendemos com o Deep Learning; conexão com redes neurais convolucionais; camadas convolucionais, Autoencoders e Autoencoders em cascata como extratores de características e redutores de dimensionalidade. Apanhado das temáticas aprendidas e troca de ideias sobre a “A4 de consulta” + sessão de dúvidas p/ P1;

22 de abril (4^{af}) e 27 de abril (2^{af}): P1 em PSI3471 – ou seja, dentro da semana de provas P1 da Elétrica (em 20 de abril, pela ponte de Tiradentes, não há aula na 2^a feira)

#13 (29/abril – 4^{af}) 1) Parte das temáticas e atividades desta aula após a P1 serão definidas mais adiante no semestre, de acordo com a evolução das aulas anteriores; 2) Conexão do aprendido até o momento com as próximas temáticas no curso.