

Aulas PSI3471 #1 (18/2) a #15 (22/4) - Prof Emilio: Registro de temáticas e de tarefas

#1 (18/02) Calendário, contextualização da disciplina no curso E&S e com as demais linhas formativas; primeiro apanhado das temáticas do semestre, com a presença dos dois professores responsáveis (Emilio e Hae).

#2 (20/02) Conceitos em regressão não linear e em regressão multivariada; contraste com técnicas já conhecidas como a regressão linear univariada.

(Tarefa 1) Atividade em sala com entrega: elaboração pelo aluno de regressor multivariado relevante a Eletrônica e Sistemas (ou ênfase própria) e discussão com colegas da utilidade e viabilidade – entrega em sala no 20/fevereiro

#3 (25/02) Conceitos em reconhecimento de padrões multivariados; elementos matemáticos em regressão linear multivariada e em discriminadores lineares multivariados

#4 (27/02) Neurônios biológicos como base para os neurônios artificiais; equações e propriedades matemáticas do neurônio artificial isolado; relação com regressores e discriminadores lineares multivariados.

(Tarefa 2) Atividade em sala com entrega: elaboração de reconhecedor de padrões multivariado próprio relevante a Eletrônica e Sistemas (ou outra ênfase) e crítica da utilidade e viabilidade – entrega em sala no 27/fevereiro

#5 (11/03) Redes de Neurônios Artificiais (RNAs) conjugando múltiplos neurônios; arquiteturas neurais diversas; arquiteturas MLP – Multi Layer Perceptron; primeiro contato com o ensaio computacional de redes neurais – ambiente MBP – Multiple Back Propagation.

#6 (13/03) 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.

(Tarefa 3) Iniciada em sala: definição pelo aluno de componentes de regressão reconhecimento de padrões multivariados para um potencial TCC – entrega de relatório via e-disciplinas em 15/março

#7(18/03) Grafos da computação em redes neurais do tipo MLP; notação matemática para pesos sinápticos, variáveis de entrada, saída e variáveis intermediárias no MBP; exemplares / observações empíricas para o treinamento supervisionado em MLPs; aprendizado com base na propagação reversa do erro (EBP).

#8 (20/03) Gradiente descendente e otimização de pesos sinápticos com base no conjunto de treino e EBP; dedução das fórmulas do EBP, em sala de aula e em conjunto com os alunos: trabalho focado num peso sináptico específico da rede, escolhido pelo professor para máxima complexidade da dedução.

#9 (25/03) 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.

(Tarefa 4) Atividade iniciada em sala: derivação das equações do EBP, com entrega via e-disciplinas posteriormente: generalização da dedução obtida em sala, para pesos sinápticos distintos do focado em sala – entrega de relatório via e-disciplinas em 04/abril

#10 (27/03) Regra “Delta” de aprendizado de Widrow, para neurônio isolado; Aprendizado por EBP recursivo, camada a camada. Resultados de Cybenko revisitados para o caso simples de aproximação de funções univariadas.

#11 (01/04) 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.

#12 (03/04) Soluções em reconhecimento e em regressão empregando dois estágios: primeiro estágio para extração de características / medidas e redução de dimensionalidade + segundo estágio MLP como reconhecedor / regressor genérico; técnicas diversas de extração de características em projetos concretos. Extensões de análise harmônica para a extração de características; conceitos básicos em análise tempo-frequência.

#13 (08/04) PCA - Análise de Componentes Principais como extratores de características. Autoencoders e Autoencoders em cascata como extratores de características e redutores de dimensionalidade. Medidas de qualidade diversificadas para regressores multivariados (distintas do erro quadrático médio); Flutuação do desempenho do modelo com a amostras de treino e teste e técnicas de reamostragem: técnica de validação cruzada, k-fold cross validation e leave one out.

#14 (10/04) Construindo reconhedores de padrões com fronteiras de separação genéricas: separadores lineares, bancos de separadores lineares como aproximadores de fronteiras genéricas e circuitos combinatórios, se suas implementações com computação neural e MLPs. Técnicas de medida de qualidade em reconhedores de padrões: matriz de confusão, conceitos de falsos positivo e negativo, especificidade e sensibilidade.

(Tarefa 5) Simulação computacional no ambiente MBP de redes neurais para a regressão não linear multivariada e o reconhecimento de padrões, com entrega via e-disciplinas em 22/abril

#15 (22/04) Plano: apanhado breve das temáticas aprendidas e início da preparação da “A4 de consulta” (Tarefa #6) + sessão de dúvidas para a P1; Avançando na conexão do aprendido até o momento com o Deep Learning; conexão com próximos passos da disciplina (pós P1).

(Tarefa 6) Iniciada na aula #15 e apresentada ao professor em papel na P1 às 7:30 de 06/maio, já identificada e assinada no topo: A4 de consulta com anotações pessoais de estudos para a P1 entregue ao final junto com a prova.