

Modelo preliminar de aprendizagem de máquina para mitigação de modificações na estrutura didática de instituições de ensino

Prof. Me. Vitor M. Quintella – vitor.quintella@gmail.com
Faculdade Social Sul Americana - UNIFASS

RESUMO

Embora um docente bem formado tenha a capacidade de adaptar a sua abordagem ao perfil da turma, o professor necessita de um período razoável para reconhecimento do perfil da turma, bem como para identificação das melhores ferramentas para se adequar a este perfil. Como esse período inicial de caracterização e adequação do ferramental didático ocorre simultaneamente à carga horária letiva inicial, é uma suposição razoável que a carga horária inicial não seja aproveitada de forma ótima, não devido ao corpo docente ou discente, mas sim devido à estrutura em si. Essa utilização não ótima da carga horária, pode ser tipicamente mitigada pela experiência, tanto do docente, quanto do discente quanto da instituição. Assim, através de um sistema de aprendizagem de máquina que auxilie o planejamento do docente é possível utilizar dados históricos de elementos do ensino, como o perfil de cada aluna e de cada assunto da matéria, dispor de um conjunto de sugestões para auxiliá-lo a adequar sua abordagem antes mesmo do início da matéria. O mesmo sistema de aprendizagem virtual, aqui proposto, pode ainda reduzir perdas de experiência da instituição decorrentes de alterações graves no sistema de ensino.

INTRODUÇÃO

A aplicação da aprendizagem de máquina tem sido uma área de rápido desenvolvimento, permitindo sua utilização nas mais diversas aplicações acadêmicas e profissionais, embora ainda existam espaços inexplorados pela mesma no auxílio ao processo de ensino e aprendizagem. Avanços recentes foram feitos no campo da educação utilizando aprendizado de máquinas, embora esse aprendizado seja orientado à educação, sua utilização geralmente é orientada ao ensino e à avaliação automática (por um sistema digital) dos alunos, simulando a presença de um professor cf. Blanco e Gonzalez, 2014.

Dentre as diversas incumbências próprias de um docente e de sua instituição, se encontra a da adaptação do processo didático à realidade específica de cada turma e, na medida do possível, a cada aluno. Esse processo ocorre de forma orgânica, e se desenvolve gradualmente, à medida em que ocorrem as interações entre docente, discentes e estrutura da instituição de ensino. A importância da adequação dos ambientes de ensino aos estilos de

aprendizagem é destacada por Molina (2017) especialmente quando se trata de ambientes com interfaces virtuais.

Todo o processo de adequação do ensino, porém, que depende da estrutura acima destacada, sofre perdas, toda vez que a estrutura em si sofre alguma quebra conceitual. A mudança de turmas a cada semestre ou ano, faz com que o processo de adequação precise recomeçar outra vez. Assim, dentro de uma estrutura de ensino limitada por uma carga horária pré-determinada a utilização dessa carga horária no processo de ensino pode ser dividido em duas etapas: a primeira parte sendo mais intensa em adequação da abordagem e do ferramental didático ao perfil da turma, e a segunda parte mais intensa na eficiência do processo de ensino com o instrumental didático já personalizado ao perfil da turma – inclusas suas individualidades.

Convém destacar que outras quebras na estrutura didática ainda podem afetar a adequação da abordagem didática, tal como mudanças nas ementas, mudanças de professores, inclusão de novos alunos oriundos de outras turmas ou instituições ou, ainda, a própria mudança no perfil do corpo discente.

Este processo, repetitivo, de readequação da estrutura didática implica em um contínuo ciclo de perda e recuperação de eficiência de ensino. Ou seja, a primeira parte da carga horária do ensino contem uma utilização não-ótima do ferramental didático disponível, até que o mesmo seja adequado ao perfil da turma. Por sua vez, docentes e instituições experientes irão sofrer menos esta perda devido à sua capacidade de, baseado em experiências anteriores, identificar mais rapidamente o perfil da turma e a abordagem de ensino ótima. O processo de estruturação didática de uma instituição é tratado por Molano e Martin (2017) que identifica o processo de aprendizagem do corpo docente na utilização métodos de ensino diferenciados (como estudos de caso) para aplica-los em sala de aula.

Dentre outras funcionalidades da aprendizagem de máquinas, a mesma permite, com base em dados históricos, identificar e classificar características de grupos, bem como prever características de suas associações, permitindo a identificação de decisões ótimas para os futuros mais prováveis (cf. Chakraborty e Joseph, 2017). Esse processo é semelhante ao processo de experiência de docentes e instituições em antever as melhores formas de ensino e rapidamente adequá-las a cada conjunto discente.

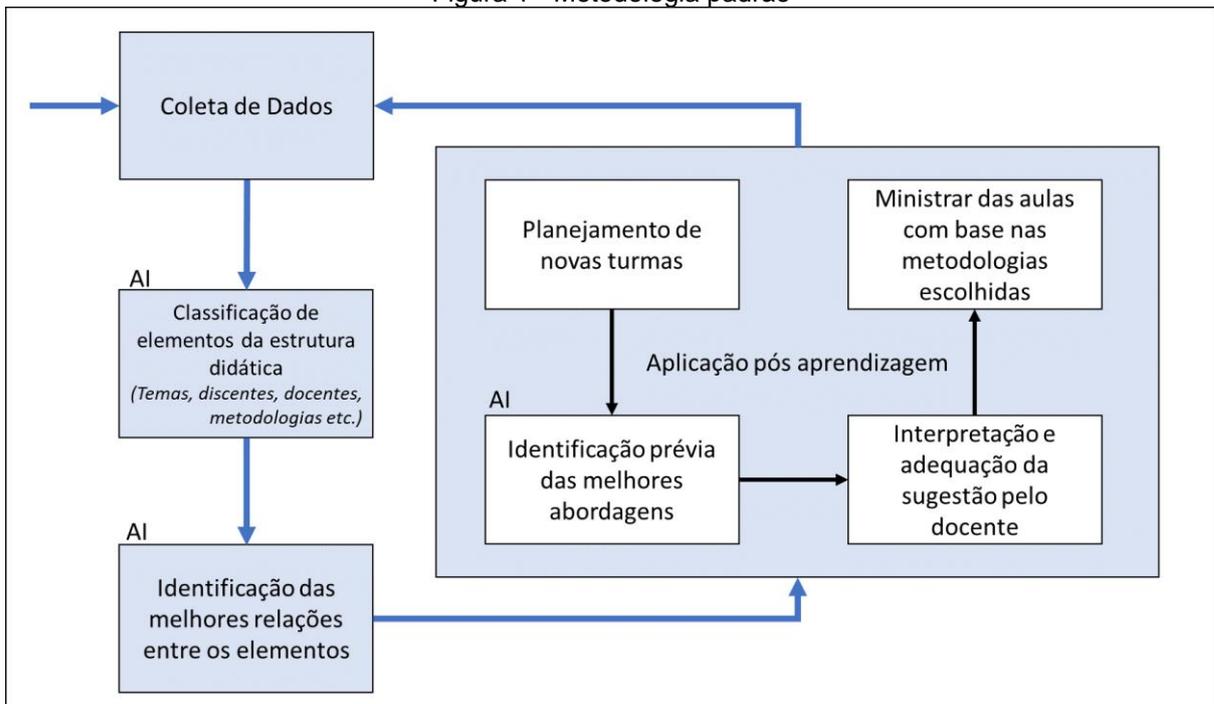
Deste modo, a utilização de aprendizagem de máquina se torna uma possível abordagem para lidar com as constantes mudanças na estrutura de ensino e como uma forma de auxiliar o docente e a instituição de ensino a identificar as melhores para cada turma, antes mesmo da carga horária começar a ser ministrada. Esta abordagem permitiria uma mitigação do impacto de mudanças na estrutura didática de ensino, auxiliando o docente a um melhor aproveitamento da carga horária inicial da matéria fornecendo previamente adaptações necessárias para o melhor ensino a conjuntos de discentes específicos.

METODOLOGIA PROPOSTA

O presente trabalho propõe uma metodologia que envolve um conjunto de técnicas de aprendizagem de máquina aplicados ao processo didático, visando a redução do impacto de modificações na estrutura didática em uma instituição de ensino. A escolha dos métodos específicos de aprendizagem de máquina utilizados irá variar de acordo com cada aplicação real com base em: volume de dados disponíveis, perfil dos dados disponíveis, capacidade de processamento disponível, grau de virtualização do ambiente de aprendizagem e características próprias da instituição e do corpo docentes e discente. Porém, é possível definir previamente o tipo de aprendizagem a ser utilizada em cada etapa, estabelecendo assim uma metodologia padrão adaptável a cada cenário específico.

A metodologia prévia padrão está apresentada na Figura 1, onde o uso do aprendizado de máquina está identificado pela presença da sigla "AI" (*Artificial Intelligence*). O processo começa pela etapa de coleta de dados, na qual seria necessário coletar dados referentes a todos os elementos da estrutura didática, tais como assuntos, matérias, materiais didáticos utilizados, metodologias e ferramentas de ensino, docentes e discentes. Alguns já estarão disponíveis na instituição na forma de planos de ensino, planos de aula, históricos curriculares e outras formas de registro típicas, outras deverão ser coletados tendo em vista esta aplicação. Esse processo de coleta de dados, se torna posteriormente uma parte do processo cíclico de aplicação da metodologia.

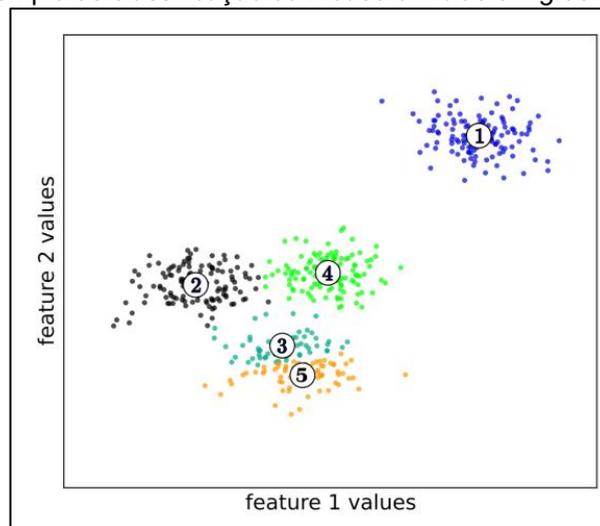
Figura 1 - Metodologia padrão



Fonte: Autoria própria

A segunda etapa, se daria através do uso de algoritmos de aprendizagem de máquina não supervisionados, ou seja, algoritmos de classificação tais como, “*k-Means*” ou “*hierarchical clustering analysis*” (HCA) devido à sua alta flexibilidade em processos classificatórios. Cabe destacar que essa classificação é não supervisionada, ou seja, busca encontrar padrões nas características dos elementos que permita categorizá-los, mas não necessita a identificação de cada classificação. Essa abordagem serve apenas como etapa intermediária para o processo de tomada de decisão, e os grupos gerados irão considerar uma série de relações correlações encontradas, de tal forma que as classificações muitas vezes não serão interpretáveis. Essa abordagem é importante pois permite preservar a privacidade das pessoas parte do processo de ensino, dispensando qualquer classificação inteligível dos mesmos. A Figura 2 apresenta um exemplo bidimensional de classificação por *clustering*.

Figura 2 - Exemplo de classificação com base em *clustering* de duas dimensões



Fonte: Chiranjit e Joseph, 2017

Um exemplo de classificação no meio didático é o mapa temático proposto por Villalustre e Del Moral (2011), mas “mapas” semelhantes poderiam ser montados não apenas para os temas, mas para todos os outros elementos do processo didático. A diferença neste método é que, por ser um processo não-supervisionado, não haveria necessidade da nomeação de cada grupo.

A etapa posterior é a identificação – por meio de regressão – das abordagens mais importantes para cada combinação de categorias dos distintos elementos. Aqui seria possível identificar as melhores abordagens e metodologias didáticas para o conjunto docente, discente e tema que será abordado. Aqui, técnicas como “*k-NN*”, “*tree model*”, “*random forest*”, “*artificial neural network*” (ANN), ou “*support vector machine*” (SVM) poderiam ser utilizadas para identificação da melhor regressão. A abordagem aqui seria supervisionada e por isso

estaria sempre associada a medidas de desempenho, essas medidas históricas, podem ser tanto as notas previamente existentes no sistema, quanto avaliações do docente por parte dos discentes ou, ainda, avaliações e questionários desenvolvidos especialmente para a parametrização do modelo utilizado nessa metodologia. É importante destacar que tecnologias semelhantes já são aplicadas para acompanhamento de outras variáveis, inclusive com leituras de texto, como poderia ser realizado com os planos de ensino. Por exemplo, Nassirtoussi *et al.* (2014) apresentam uma revisão de diversas aplicações de mineração de texto tendo vista previsão de índices de mercado.

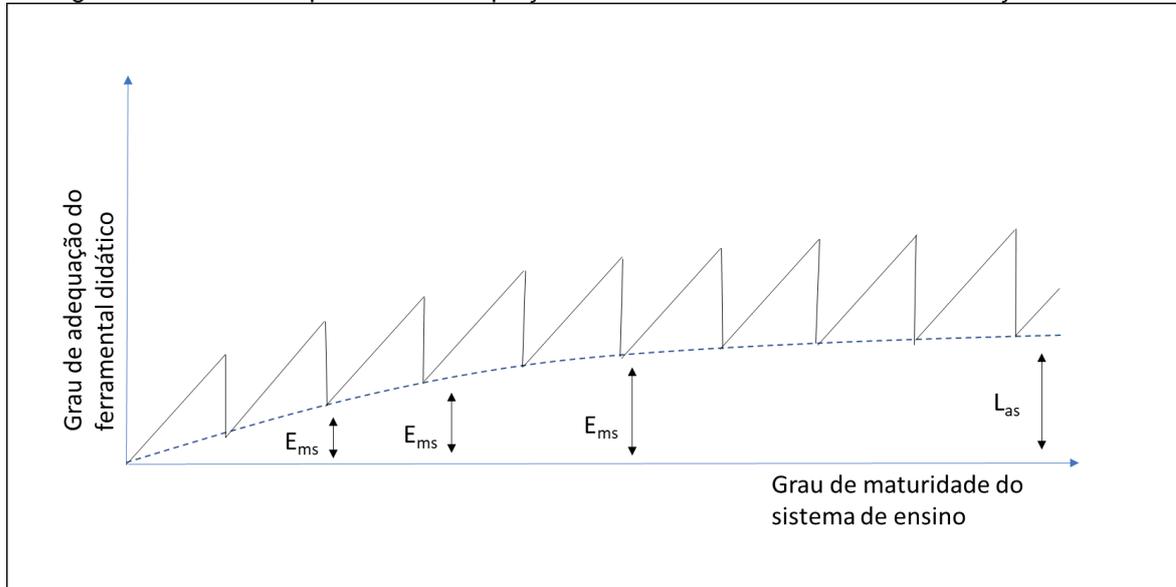
A quarta etapa do processo é a aplicação pós-aprendizagem, ela deve ser realizada sempre que se formar novos conjuntos docentes-discentes-matéria, tipicamente em mudanças de semestres ou anos, ou quando se mostrar necessário por exceções. Esta etapa está dividida em quatro partes sendo a primeira parte – que já é tipicamente executada em qualquer instituição – a formação das novas turmas, de acordo com o planejamento acadêmico. A segunda parte dessa etapa seria a utilização da aprendizagem realizada para estabelecer com base na regressão da etapa três, a melhor abordagem para essa turma nova com base na combinação dos elementos classificados na etapa dois. A terceira parte dessa etapa é a interpretação do docente das sugestões propostas, destacando que a utilização de inteligência artificial apenas auxilia como ferramenta e não visa substituir a perspectiva humano-didática. Esta terceira parte é uma variação da adaptação que o professor tipicamente faz, mas com esse método ela poderá ser realizada antes do contato entre docente e discentes, começando a matéria já com uma abordagem mais adequada ao perfil da turma. A Quarta parte da quarta etapa é processo típico de ministrar aula com base no ferramental escolhido para o problema. Esta quarta etapa liga-se à coleta de dados reiniciando o processo cíclico e aprimorando continuamente o sistema.

RESULTADOS ESPERADOS

Embora mudanças no sistema de ensino irão inevitavelmente ocorrer em perdas de adequação da metodologia didática, a aplicação deste método poderá reduzir o impacto dessas perdas, mitigando o impacto das mudanças sobre o processo de aprendizagem. Assim, uma representação do sistema típico de grau de adequação do ferramental em função do grau de maturidade do sistema de ensino é apresentada na Figura 3, no qual a linha contínua representa o processo cíclico de união docente-discentes em disciplinas ou matérias semestrais ou anuais, na qual a cada nova combinação, o ferramental precisa ser novamente adequado, alcançando seu ponto ótimo apenas quando a carga horária acaba. Nesta representação foi incluído o processo de maturidade do sistema de ensino, no qual através da experiência do docente, da instituição ou do corpo discente, o impactado das mudanças

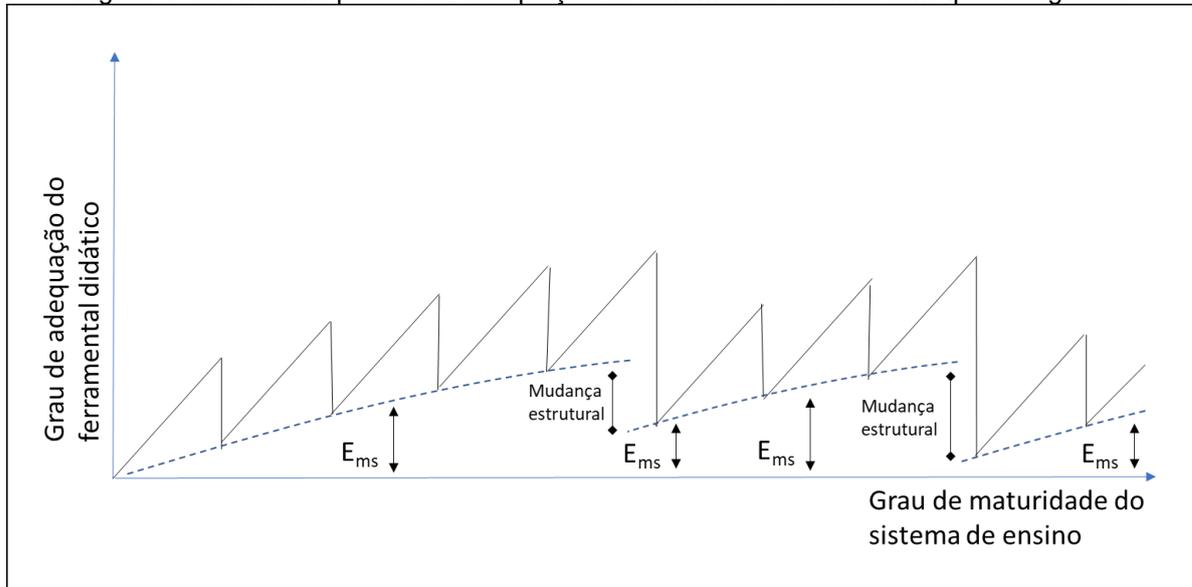
cíclicas é reduzido por uma Experiência de maturidade do sistema (E_{ms}). Essa experiência, decorrente da maturidade, permite uma previsibilidade do melhor ferramental para uma turma, mas essa experiência estaria limitada por um Limite assintótico do sistema (L_{as}) já que inevitavelmente turmas novas trarão característica e desafios novos.

Figura 3 - Movimento padrão de adequação do ferramental didático com mudanças cíclicas



Fonte: Autoria própria

Figura 4 - Movimento padrão de adequação do ferramental didático com quebras graves



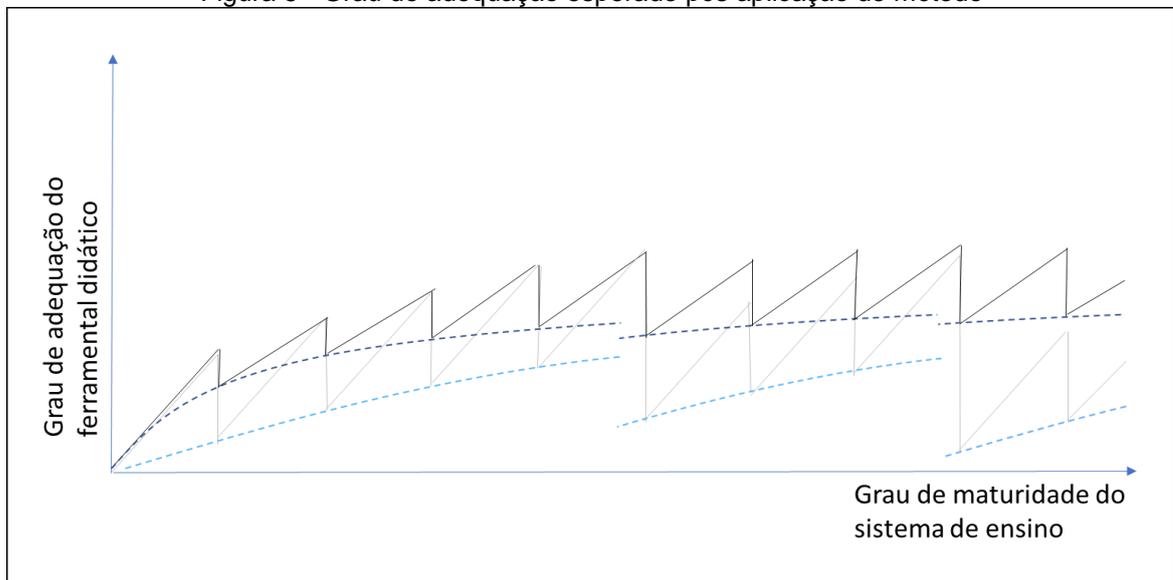
Fonte: Autoria própria

Observe-se que o cenário representado na Figura 3 leva em conta apenas mudanças cíclicas no processo de ensino, quando na realidade o processo estaria susceptível também a mudanças não cíclicas – graves, como mudanças no corpo docente, nas grades

curriculares, no ementário, no perfil do discente ingresso ou até na gestão da própria instituição, o que levaria a perdas maiores e não cíclicas do sistema, como por exemplo pela aposentadoria de professores bastantes experientes, como apresentado na Figura 4. Aqui mudanças estruturais no sistema de ensino iriam implicar em perdas da Experiencia de maturidade do sistema (E_{ms}). Levando à necessidade de todo o processo de reestruturação em busca do limite assintótico.

Uma vez instalado o método, algumas respostas seriam esperadas do sistema de ensino. Primeiro, é esperada a aceleração no processo de se adquirir a Experiencia de maturidade do sistema (E_{ms}) uma vez que a esse processo seria acrescido a aprendizagem de máquina; segundo, é esperado um Limite assintótico do sistema (L_{as}) maior, uma vez que – diferente de pessoas – um sistema de aprendizagem de máquina é capaz de absorver grandes quantidades de dados verificando as suas diversas correlações lineares e não lineares; por fim, o terceiro resultado esperado seria a mitigação dos impactos de mudanças estruturais graves, uma vez parte da experiencia de maturidade do sistema não estaria atrelado a pessoas físicas, mas sim a um banco de dados processado digitalmente. De tal forma que o resultado esperado seria de acordo com a Figura 5. Esta figura possui os resultados anteriores ao fundo, em cinza.

Figura 5 - Grau de adequação esperado pós aplicação do método



Fonte: Autoria própria

Assim, através da aplicação do método, espera-se alcançar novos patamares de correspondência e adequação entre métodos de ensino e o conjunto discentes-docente ao qual são aplicados. Espera-se sobretudo mitigar os impactos de mudanças graves esporádicas e de mudanças cíclicas comuns.

CONSIDERAÇÕES FINAIS

É certo que a presença de um professor competente é indispensável à realização de um bom processo de mediação do conhecimento junto à um corpo discente. Esse trabalho propôs um método para, através da aprendizagem de máquinas, permitir ao docente um melhor aproveitamento da carga horária inicial de sua matéria, acelerando o processo de adequação do ferramental didático à turma. Outros resultados esperados são o de melhor lidar com mudanças graves, bem como melhor munir o professor para atender às demandas didáticas da turma.

O método se apresenta ainda em estado inicial, mas sua proposta se mostra factível devido à existência e aplicação dessas tecnologias em outros ambientes. Os resultados esperados se mostram validos embora a mensuração da ordem de grandeza do impacto do mesmo ainda não seja mensurável. Estudos futuros devem envolver identificação, através de questionários aplicados a docentes e discentes, do tempo e da qualidade de adequação do método didático a turmas específicas. Uma vez identificado o tamanho desse impacto, um trabalho futuro trataria da identificação e do desenho de bases de dados para a categorização não-supervisionada.

REFERÊNCIAS

- Blanco, L.C., e Gonzales, O.L.P, **Contribuciones de la Inteligencia Artificial a la Educación Superior**. In: VIRTUAL EDUCA 2014, 2014. Disponível em: <http://virtualeduca.info/CDISBN/isbn.html>, acesso em: 12 de março de 2018
- Chiranjit, C. e Joseph, A., **Machine learning at central banks**, Staff Working Paper No. 674, Bank of England, 2017, Disponível em: <https://www.bankofengland.co.uk/working-paper/2017/machine-learning-at-central-banks>, acesso em: 02 de março de 2018
- Molano, E.G. e Martin, M.A.E., **Los ambientes de aprendizaje, una experiencia con docentes del Programa de Becas para Excelencia Uptc, Sede Duitama** In: VIRTUAL EDUCA 2017, 2017. Disponível em: <http://virtualeduca.info/CDISBN/isbn.html>, acesso em: 12 de março de 2018
- Molina V., R., **Relación entre entornos virtuales de aprendizaje y estilos de aprendizaje en la formación de magísteres con metodología virtual**, In: VIRTUAL EDUCA 2017, 2017. Disponível em: <http://acceso.virtualeduca.red/documentos/ponencias//3840-39d7.pdf>, acesso em: 20 de março de 2018
- Nassirtoussi, A.K., Aghabozorgi, S., Wah, T.Y. e Ngo, D.C.L., **Text mining for market prediction: A systematic review**, Expert Systems with Applications, n. 41, 2014, pp.7653–7670
- Villalustre, L.; Del Moral, M., **Contenidos on line adaptados a los estilos cognitivos de los estudiantes a través de mapas conceptuales en ruralnet**. In: Tendencias Pedagógicas. N. 17. 2011, pp 117 – 132. Disponível em: <https://dialnet.unirioja.es/descarga/articulo/3653756.pdf> , aceso em 20 de março de 2018