

FORMAÇÃO DE AGRUPAMENTOS HOMOGÊNEOS DE TRABALHADORES ATRAVÉS DE CURVAS DE APRENDIZADO

Renato Eduardo Stroeike

Universidade Federal do Rio Grande do Sul (UFRGS)
Av. Osvaldo Aranha, 99 - 5º andar, Porto Alegre/RS - 90.035-190
renatoes@producao.ufrgs.br

Flavio S. Fogliatto

ffogliatto@producao.ufrgs.br

Michel J. Anzanello

anzanello@producao.ufrgs.br

RESUMO

O agrupamento de trabalhadores com perfis similares de aprendizado mostra-se útil em diversas aplicações industriais. Este artigo propõe um método de agrupamento de trabalhadores baseado em técnicas de clusterização e balizado por curvas de aprendizado (CA). Diversos modelos de CAs são testados em dados de desempenho coletados de processo; os parâmetros gerados pelas CAs permitem prever o desempenho dos trabalhadores em intervalos de tempo pré-determinados. Os valores preditos são agrupados através de ferramentas de clusterização. Um Índice de Ajuste (IA), gerado a partir do *Silhouette Index* e do coeficiente de determinação, indica a melhor CA em termos de aderência aos dados e qualidade de agrupamento de perfis de aprendizado. A aplicação do método em uma indústria de calçados gerou agrupamentos consistentes de trabalhadores com base nos distintos perfis de aprendizado.

PALAVRAS-CHAVE. Curvas de Aprendizado, Clusterização, Agrupamento de trabalhadores.

Área principal: Estatística, Outras aplicações em PO, PO na indústria.

ABSTRACT

In many industrial segments it is desirable to group workers with similar learning profiles. This paper presents a method aimed at grouping workers based on learning curve (LC) modeling and clustering techniques. Workers' data performance are modeled through several LC models; learning parameters allow to predict the performance of workers at intervals of predetermined time. The predicted values are then grouped through clustering techniques. The largest Adjustment Index (AI), derived from the *Silhouette Index* and Coefficient of Determination, indicates the model yielding superior adherence to data and better grouping of learning profiles. When applied to a shoe manufacturing process, the method generated consistent groups of workers based on their learning profiles.

KEYWORDS. Learning Curves, Clustering, Groups of Workers.

Main Area: Statistics, Other applications in OR, OR in industry.

1. Introdução

O agrupamento de trabalhadores conforme seu perfil de aprendizado tem se mostrado relevante em diversos cenários produtivos. Em linhas de montagem manual, é desejado que trabalhadores reunidos em uma estação de trabalho apresentem perfis similares de aprendizado, assegurando o balanceamento da carga de trabalho na estação. Tal condição é especialmente importante em linhas cujos produtos apresentam elevados níveis de customização, demandando constante aprendizado dos trabalhadores em relação aos procedimentos de execução de um novo produto.

As sistemáticas utilizadas para agrupar trabalhadores com características similares usualmente focam-se no tempo de produção ou método de trabalho, valendo-se do princípio taylorista de especialização do trabalho. No entanto, tais sistemáticas podem conduzir a resultados imprecisos em situações em que o trabalhador é submetido a frequentes processos de aprendizado. Essa imprecisão é justificada pela dificuldade em estimar o tempo padrão de execução de uma atividade durante o processo de aprendizado do trabalhador, visto que não se trata de uma variável pontual, mas sim de uma variável funcional.

Abordagens para o agrupamento de trabalhadores segundo seus perfis de aprendizado são bastante escassas na literatura, limitando-se ao estudo de Uzumeri e Nembhard (1998). Tais autores utilizam os parâmetros da curva de aprendizado reportada por Mazur e Hastie (1978) para descrever padrões de habilidade em uma população de trabalhadores. O método proposto, no entanto, foca-se nos parâmetros gerados pela modelagem da curva de aprendizado, e não nos dados de desempenho que compõem o perfil.

O presente artigo propõe um método de agrupamento de trabalhadores com perfis similares de desempenho através da modelagem por curvas de aprendizado (CA) e métodos de clusterização. Para tanto, dados de desempenho dos trabalhadores são modelados por seis curvas de aprendizado. Os parâmetros estimados geram previsões acerca do perfil de desempenho dos trabalhadores, os quais são então agrupados através de técnicas de clusterização. Uma análise hierárquica permite definir o número provável de agrupamentos a serem gerados; uma análise *k*-means é então utilizada para agrupar os trabalhadores. O melhor modelo de curva, e consequente agrupamento, é escolhido através de um Índice de Ajuste, gerado a partir de um índice de aderência de cada modelo aos dados (R^2), e de um indicador de qualidade dos agrupamentos gerados (denominado *Silhouette Index*).

O restante deste trabalho está estruturado da seguinte forma. A seção 2 traz uma breve revisão da literatura em torno dos modelos de curva de aprendizado. Na seção 3 é apresentada a metodologia proposta. Um estudo de caso aplicado em uma indústria de calçados é apresentado na seção 4. Por fim, tem-se a conclusão do artigo na seção 5.

2. Referencial teórico

Curvas de Aprendizado (CA) são modelagens matemáticas do desempenho de um trabalhador submetido a tarefas manuais repetitivas (ANZANELLO & FOGLIATTO, 2007). Tal modelagem assume que o tempo demandado para execução de uma tarefa diminui à medida que repetições são executadas. A primeira CA foi proposta por Wright (1936), observando que a montagem de aeronaves apresentava uma redução aproximada de 20% no custo médio a cada duplicação da quantidade produzida (TEPLITZ, 1991; COOK, 1991; BADIRU, 1992; ARGOTE, 1999; ASKIN, 2001; ANZANELLO & FOGLIATTO, 2007). Tal fenômeno de redução de custos já havia sido observado na indústria aeronáutica por Rohrbach (1927), porém sem maiores análises do processo de aprendizado (BISKUP, 2007).

Os fatores que proporcionam o aprendizado são complexos e ainda não plenamente compreendidos (ADLER & CLARK, 1991). Uzumeri e Nembhard (1998) e Anzanello e Fogliatto (2007) demonstram que trabalhadores que aprendem de forma mais gradual alcançam padrões elevados de produtividade. Além disso, trabalhadores que aprendem mais rapidamente

também tendem a esquecer mais rapidamente durante paradas na produção (NEMBHARD & UZUMERI, 2000).

Desde o seu desenvolvimento, as CAs têm se mostrado uma importante ferramenta na análise de processos industriais. Corominas *et al.* (2010) formalizaram o problema de atribuição e de agendamento de um conjunto de tarefas, considerando o desempenho dos trabalhadores em uma tarefa como dependente da experiência na atividade e em outras similares. Cohen *et al.* (2008) estudaram o problema de alocação de trabalhadores em linhas de montagem, diminuindo o *makespan* (tempo total de produção). Similarmente, Toksari *et al.* (2008) elaboraram um algoritmo para balanceamento de linhas de montagem sujeitas ao efeito de aprendizado, tendo por objetivo diminuir o número de estações de trabalho e o tempo de ciclo nestas estações, enquanto que Prochno (2004) relatou o desempenho do primeiro ano de operação de uma nova planta automotiva através de CAs.

Outras áreas também valem-se dos benefícios da modelagem por CA. Ngwenyama *et al.* (2007) apresentaram uma abordagem para atualização de *softwares*. Focados na área de inovação e produção, Pruett e Thomas (2008) concluíram que quanto melhor o processo de aprendizado na área de inovação da empresa, menos intenso será o efeito do aprendizado na produção. O autor observou que o processo de aprendizado também ocorre no desenvolvimento de produtos e que possíveis deficiências no desenvolvimento só serão observadas na produção.

A necessidade de agrupar trabalhadores por similaridade de aprendizado é conhecida, porém ainda pouco desenvolvida na literatura sobre CAs. Cohen *et al.* (2008) verificaram que a alocação de trabalhadores é melhor alcançada quando, para uma dada atividade em conjunto (como ocorre em uma estação de trabalho, por exemplo), são agrupados trabalhadores com perfis similares de aprendizado. Valendo-se da curva hiperbólica de três parâmetros, Anzanello e Fogliatto (2007) propuseram um método para alocação de trabalhadores a tarefas específicas em linhas de montagem. Os parâmetros gerados pelas curvas de aprendizado são analisados em dois cursos distintos de ação, de acordo com a duração estimada da corrida de produção. Ferramentas de clusterização também são utilizadas, porém limitam-se ao agrupamento de modelos de produtos de acordo com sua complexidade.

Uzumeri e Nembhard (1998) utilizaram CAs com vistas à identificação de agrupamentos de trabalhadores. Os autores observaram 3874 casos de aprendizado em uma manufatura americana. Cada trabalhador foi modelado através de uma CA, e os parâmetros utilizados para estimar o comportamento do grupo através de análise gráfica. Pôde-se observar a existência de três agrupamentos de trabalhadores. O primeiro era formado pelos parâmetros de trabalhadores que saíram antecipadamente do treinamento inicial, indicando baixo desempenho. O segundo representava o comportamento oposto, agrupando trabalhadores que possuíam experiência prévia e que desempenhavam as atividades de forma mais eficiente. Um terceiro agrupamento abrigava os parâmetros da maioria dos trabalhadores, caracterizados por um perfil médio de aprendizado.

O presente trabalho difere de Uzumeri e Nembhard (1998) na forma de identificar os padrões coletivos de aprendizado. Neste estudo, o agrupamento de trabalhadores ocorre com os valores de desempenho previsto pelas curvas, as quais foram geradas com base nos parâmetros obtidos na regressão. São utilizadas, também, técnicas de estatística multivariada que permitem verificar a qualidade dos agrupamentos, em oposição à identificação visual de agrupamentos proposta por Uzumeri e Nembhard (1998).

3. Sistemática Proposta

O método proposto para o agrupamento de trabalhadores com perfis semelhantes de aprendizado é assim operacionalizado. Selecionam-se J ($j = 1, \dots, J$) trabalhadores que terão seus tempos de aprendizado monitorados. No momento em que o trabalhador é apresentado a uma nova tarefa, inicia-se a medição do tempo demandado para execução de cada repetição. Idealmente, são coletados os tempos desde a primeira repetição (a partir do momento em que o trabalhador é apresentado à tarefa), até o momento em que não há variações significativas nos dados coletados.

Os dados de desempenho de um trabalhador j são então modelados através de seis modelos de curvas de aprendizado: (i) Curva Potencial, (ii) Plateau, (iii) Stanford-B, (iv) Hiperbólico de 2 parâmetros, (v) Hiperbólico de 3 parâmetros, e (vi) Exponencial de 3 parâmetros. Os modelos (i) a (iii) modelam o tempo demandado por repetição, enquanto que os modelos (iv) a (vi) modelam o número de repetições efetivadas em determinado intervalo de tempo. Tal diferença deve-se a aspectos estruturais dos modelos, os quais são apresentados na sequência.

O primeiro modelo considerado é o Modelo Potencial proposto por Wright (1936), apresentado na eq. (1). Na equação, y indica o tempo necessário para executar uma repetição da operação em análise, C_1 é o tempo de execução da primeira repetição e b é a constante de aprendizado, que varia de 0 a -1 . Quanto menor o valor do parâmetro de aprendizado, maior é a taxa de aprendizado.

$$y = C_1 x^b \quad (1)$$

O segundo modelo considerado, do Plateau, difere-se da eq. (1) pelo acréscimo de uma constante C , que impõe um limite para o processo de aprendizado, indicando o máximo desempenho que o trabalhador poderá atingir. O modelo é dado na eq. (2).

$$y = C + C_1 x^b \quad (2)$$

O terceiro modelo considerado é o modelo de Stanford- b , também uma modificação do Modelo de Wright, representado na eq. (3). A modificação consiste em adicionar o parâmetro positivo B , que representa a experiência prévia do indivíduo, medida em unidades previamente produzidas.

$$y = C_1 (x + B)^b \quad (3)$$

O quarto modelo avaliado, Hiperbólico de 2 Parâmetros, baseia-se na proposição de Mazur e Hastie (1978), sendo apresentado na eq. (4). Enfatiza-se que a notação difere dos modelos anteriormente apresentados, sendo y o número de unidades produzidas em um dado intervalo de tempo e x o intervalo de tempo considerado. Neste modelo, o parâmetro de aprendizado é representado por r ; o parâmetro k indica o nível máximo de aprendizado.

$$y = k \left(\frac{x}{x+r} \right) \quad (4)$$

O quinto modelo é o Hiperbólico de 3 Parâmetros. Trata-se de uma modificação da eq. (4), à qual foi adicionado o parâmetro p , que representa a experiência prévia do trabalhador na execução da tarefa. Os demais parâmetros são como definidos na eq. (4).

$$y = k \left(\frac{x+p}{x+p+r} \right) \quad (5)$$

O último modelo é o Exponencial de 3 fatores, dado na eq. (6). Os parâmetros seguem as definições apresentadas na eq. (5).

$$y = k \left(1 - e^{-\left(\frac{x+p}{r}\right)} \right) \quad (6)$$

A qualidade do ajuste do modelo de curva de aprendizado m ($m=1,\dots,6$) aos dados de desempenho do trabalhador j é avaliada através do coeficiente de determinação R_{jm}^2 . Como um dos propósitos deste artigo é identificar o modelo que melhor se ajusta aos dados de desempenho, avalia-se a qualidade da aderência do modelo m , R_m^2 , para o conjunto de J trabalhadores, conforme a equação (7).

$$R_m^2 = \frac{\sum_{j=1}^J R_{jm}^2}{J}, \quad m = 1, \dots, M \quad (7)$$

Na sequência, os parâmetros gerados pelas modelagens são utilizados na predição de valores de desempenho y para cada trabalhador com base em um intervalo de tempo ou número de repetições pré-determinado (por exemplo, predizem-se dados de desempenho equivalentes a 2

horas de operação através do modelo hiperbólico). Tal procedimento gera um número comum de observações de desempenho provenientes de cada CA. Os valores preditos para cada trabalhador são então normalizados, tal que apresentem média 0 e desvio-padrão unitário. As observações passam a ser consideradas variáveis de clusterização no procedimento de formação de grupos.

As observações de desempenho dos J trabalhadores gerados por um modelo m são então agrupadas. Cada trabalhador é representado por um vetor contendo os valores preditos. O número provável de *clusters* a serem formados é determinado através de uma análise hierárquica. Neste tipo de análise, as observações são agrupadas segundo algum tipo de métrica de distância e as variáveis são agrupadas conforme medidas de correlação ou associação (FÁVERO et al., 2009). O número de agrupamentos é então utilizado no método k -means para a clusterização dos dados gerados pelo modelo m ; a qualidade da clusterização é medida através do *Silhouette Index*.

O *Silhouette Index* ($-1 < SI_j < 1$) mede a adequação de uma observação j (trabalhador, neste caso) ao agrupamento em que foi inserida. Valores de SI_j próximos a -1 indicam que o trabalhador j foi erroneamente inserido no agrupamento de destino. Valores do SI_j próximos a $+1$ indicam que o trabalhador está corretamente alocado em seu agrupamento. SI_j é calculado através da eq. (8), onde $a(j)$ é a média da distância do j -ésimo trabalhador a todos os demais trabalhadores pertencentes ao agrupamento no qual o j -ésimo trabalhador foi alocado. O termo $b(j)$ é a média da distância entre o j -ésimo trabalhador e todos os trabalhadores do agrupamento vizinho mais próximo. A distância Euclidiana ou de Manhattan é usualmente utilizada no procedimento.

$$SI_j = \frac{b(j) - a(j)}{\max\{b(j), a(j)\}} \quad (8)$$

A qualidade geral da clusterização dos dados de desempenho gerados pelo modelo de curva m , SI_m , é estimada através da média de SI_j para os J trabalhadores. Como os valores de SI_m variam de -1 à $+1$, os mesmos são reescalados no intervalo entre 0 e 1, criando o *Silhouette Index* Ajustado, SI_m^a . Tal procedimento restringe SI_m^a e R_m^2 ao intervalo $[0,1]$.

Por fim, gera-se o Índice de Ajuste (IA_m) para avaliação do desempenho do modelo m no agrupamento de perfis, conforme a eq. (9). O índice contempla dois aspectos importantes nos esforços de agrupamento dos perfis de aprendizado: (i) a qualidade de aderência do modelo m aos dados de desempenho, e (ii) a qualidade do agrupamento gerado pelos dados de desempenho preditos pelo modelo m . O agrupamento de trabalhadores gerado pelo modelo com máximo IA_m deve ser considerado.

$$IA_m = SI^a R_m^2, \quad m = 1, \dots, M \quad (9)$$

4. Resultados e Discussões

Foram coletados dados de desempenho de $J = 22$ trabalhadores de uma indústria de calçados localizada no sul do país. A coleta de dados ocorreu no setor de costura, visto como o de maior complexidade em termos dos procedimentos demandados. Trabalhadores com razoável experiência na operação foram considerados na coleta de dados. Os dados foram ajustados aos modelos de curvas apresentados nas equações (1) a (6) utilizando o aplicativo PASW Statistics 18. Os parâmetros e coeficientes R^2 obtidos para cada cruzamento de trabalhador e modelo de curva são exemplificados na Tabela 1 para os dois primeiros trabalhadores analisados. Valores consolidados de R_m^2 , obtidos através da eq. (7), são apresentados na primeira coluna numérica da Tabela 2.

Os parâmetros dos M modelos geraram perfis distintos de desempenho para cada trabalhador. Para os modelos das equações (1) a (3), foram preditos 140 dados de desempenho; para os demais modelos foram preditos 22 dados. Na sequência, rodou-se uma clusterização hierárquica

sobre os dados preditos por cada modelo de curva para a definição do melhor número de agrupamentos de trabalhadores. A análise dos seis dendogramas sugeriu a formação de dois agrupamentos, como exemplificado na Figura 1 para o modelo Potencial.

A seguir, os perfis de desempenho preditos para os J trabalhadores foram agrupados através da técnica não-hierárquica k -means, utilizando um valor de $k = 2$. Os perfis foram agrupados através do aplicativo Matlab versão 7.4, sendo calculado o SI_m para cada modelo de curva m (ver segunda coluna numérica da Tabela 2). O índice IA_m foi gerado através da eq. (9).

Tabela 1 – Visão parcial dos parâmetros e R^2 para os cruzamentos de trabalhadores e modelos de curvas

	Curva Potencial	Plateau	Stanford-B	Hiperbólico de 2 Parâmetros	Hiperbólico de 3 Parâmetros	Exponencial de 3 Parâmetros
Trabalhador 1	C=35,970 b=-0,127 $R^2=0,39$	C=24,758 b=-0,528 B=-18,370 $R^2=0,424$	C=35,970 b=-0,127 B=0 $R^2=0,39$	k=32,091 r=4,843 $R^2=0,55$	k=2248,688 r=-849,729 p=9,908 $R^2=0,809$	k=47263,482 r=22493,639 p=9,854 $R^2=0,711$
Trabalhador 2	C=184,766 b=-0,283 $R^2=0,822$	C=184,766 b=-0,283 B=0 $R^2=0,82$	C=220,803 b=-0,331 B=1,126 $R^2=0,831$	k=15,749 r=41,039 $R^2=0,88$	k=20,382 r=81,716 p=7,712 $R^2=0,886$	k=15,303 r=78,078 p=11,981 $R^2=0,884$

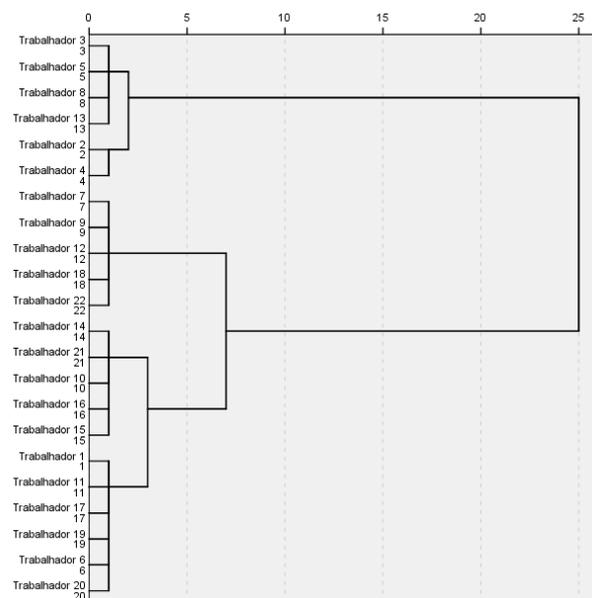


Figura 1 - Dendograma obtido pela clusterização do modelo Potencial

Tabela 2 – Valores de R_m^2 , SI_m , SI_m^a , e IA_m para os modelos de curva testados

	R_m^2	SI_m	SI_m^a	IA_m
Curva Potencial	0,5283	0,8194	0,9097	0,4806
Plateau	0,5434	0,7683	0,8841	0,4804
Stanford-B	0,5339	0,8807	0,9403	0,5021
Hiperbólico 2	0,6702	0,8046	0,9023	0,6047
Hiperbólico 3	0,7279	0,9953	0,9976	0,7262
Exponencial 3	0,7315	0,9972	0,9986	0,7305

A partir da análise dos valores de IA_m , selecionou-se o agrupamento de trabalhadores sugerido pelos dados preditos pelo modelo Exponencial de 3 parâmetros (Exponencial 3). O referido modelo apresentou um IA_m de 0,7305. Os agrupamentos obtidos a partir dos valores preditos por esse modelo vêm apresentados na Tabela 3.

Os indivíduos 1 e 16, reunidos no agrupamento 2, apresentaram um comportamento similar entre si e distinto dos demais indivíduos alocados no primeiro agrupamento. Os perfis de aprendizado para tais trabalhadores, com base no modelo exponencial de 3 parâmetros (modelo escolhido para análise), são apresentadas na Figura 2. Existe nítida similaridade entre tais perfis. A título de comparação, o perfil do trabalhador 16 é confrontado com o perfil do trabalhador 19 (escolhido aleatoriamente), alocado ao agrupamento 2 (ver Figura 3). Existem diferenças significativas na velocidade de aprendizado e no patamar final de desempenho entre tais trabalhadores. A análise do conjunto total de curvas (não ilustrado) mostra que os trabalhadores do agrupamento 2 convergem mais lentamente para o estado estacionário, indicando que ainda estão em processo de aprendizagem. Porém, uma vez atingindo o estado estacionário, tais trabalhadores apresentam produtividade mais elevada. Tal resultado corrobora os achados de Uzumeri e Nembhard (1998).

Tabela 3 – Alocação dos trabalhadores aos agrupamentos

Indivíduo	Agrupamento Alocado	Indivíduo	Agrupamento Alocado
1	2	12	1
2	1	13	1
3	1	14	1
4	1	15	1
5	1	16	2
6	1	17	1
7	1	18	1
8	1	19	1
9	1	20	1
10	1	21	1
11	1	22	1

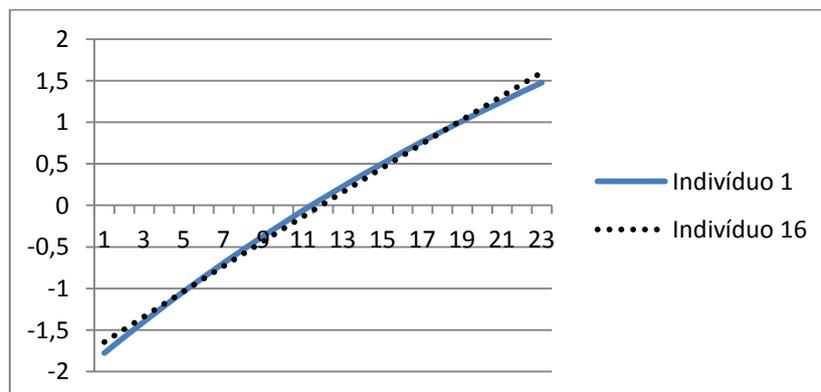


Figura 3 – Perfil de aprendizado dos trabalhadores inseridos no agrupamento 2

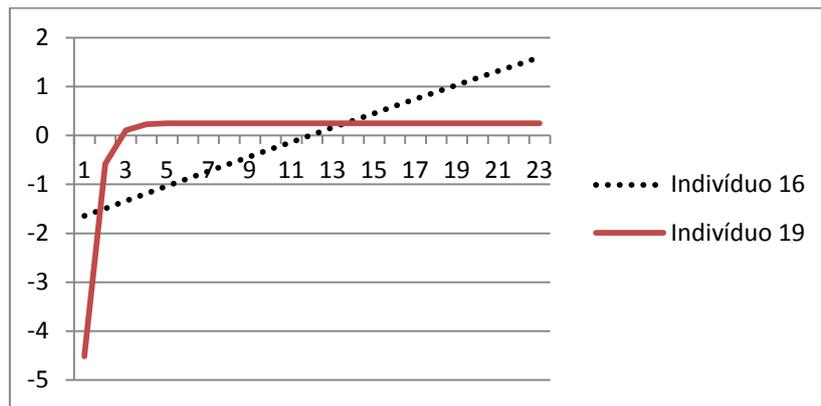


Figura 4 – Comparação entre perfis de aprendizado de dois trabalhadores em agrupamentos distintos

Com base nos resultados das modelagens, observou-se que os trabalhadores pertencentes ao agrupamento 2 apresentam um valor médio de parâmetro p (associado à experiência prévia) de 21,7. O valor médio de p dos indivíduos alocados ao agrupamento 1 é de 33,3, sinalizando uma maior experiência prévia em relação aos trabalhadores do agrupamento 1.

No caso da indústria de calçados, tal informação é útil ao alocarem-se tarefas aos trabalhadores. Os trabalhadores no agrupamento 1, caracterizados pelo rápido aprendizado, devem receber lotes de produção menores e ser submetidos a trocas constantes de lotes, já que se adaptam com maior facilidade às tarefas. O contrário ocorre com os trabalhadores inseridos no agrupamento 2, aos quais devem ser alocados lotes de maior duração; tais trabalhadores convergem a um estado estacionário com uma taxa de produção mais elevada.

5. Conclusões

O presente artigo apresentou uma metodologia na qual curvas de aprendizado são utilizadas para formar grupos de trabalhadores com perfis similares de aprendizado. O método proposto envolve técnicas de clusterização e o uso do *Silhouette Index*, juntamente com o Coeficiente de Determinação (R^2), para calcular o valor do Índice de Ajuste (IA) proposto. Esse índice permite identificar o melhor modelo de curva com base na aderência aos dados e qualidade das clusterizações geradas.

A metodologia proposta foi aplicada em uma indústria de calçados, onde o processo de aprendizado de 22 trabalhadores foi analisado. Os dados coletados foram modelados por seis modelos distintos de curvas de aprendizado (Potencial, Plateau, Stanford-B, Hiperbólico de 2 parâmetros, Hiperbólico de 3 parâmetros, e Exponencial de 3 parâmetros), gerando parâmetros de aprendizado e desempenho característicos para cada trabalhador. Valores de desempenho previstos a partir de cada modelo foram inicialmente agrupados utilizando uma técnica de clusterização hierárquica (para definição do melhor número de agrupamentos a ser usado), de onde se concluiu a existência de 2 grupos com perfis distintos de aprendizado. Na sequência, utilizou-se a técnica de clusterização *k-means* para efetivo agrupamento dos perfis, registrando-se o valor do *Silhouette Index*. Por fim, o Índice de Ajuste (IA) apontou o modelo Exponencial de três parâmetros como o responsável pela melhor modelagem e agrupamento. Os grupos gerados com base nas previsões do modelo exponencial mostram que trabalhadores alocados no agrupamento 1 são caracterizados por rápido aprendizado e patamar inferior de desempenho. Os trabalhadores alocados no agrupamento 2 apresentam uma taxa de aprendizado menor, porém atingem um patamar de desempenho maior no longo prazo.

Desdobramentos futuros incluem a utilização de técnicas de mineração de dados para a classificação dos perfis de aprendizado dos trabalhadores em diversas classes de aprendizado. A

utilização de medidas alternativas de aderência dos modelos aos dados também pode ser abordada com vistas ao desenvolvimento de índices de ajuste mais robustos.

Referências

ADLER, P.S. e CLARK, K.B. (1991), Behind the Learning Curve: A Sketch of the Learning Process, *Management Science*, 37, 267-281.

ANZANELLO, M.J. e FOGLIATTO, F.S. (2007), Learning curve modeling of work assignment in mass customized assembly lines, *International Journal of Production Research*, 45, 2919-2938.

ARGOTE, L. *Organizational Learning: Creating, Retaining and Transferring Knowledge*. Springer: New York, 1999.

ASKIN, R. e GOLDBERG, J. *Design and Analysis of Lean Production Systems*. Wiley: New York, 2001.

BADIRU, A.B. (1992), Computational Survey of Univariate and Multivariate Learning Curve Models, *IEEE Transactions on Engineering Management*, 39, 176-188.

BISKUP, D. (2008), A state-of-art review on scheduling with learning effects, *European Journal of Operational Research*, 188, 315-329.

COHEN, Y., DAR-EL, E.M., VITNER, G. e SARIN, S.C. (2008), Allocation of work to the stations of an assembly line with buffers between stations and three general learning patterns, *Int. J. Intelligent Systems Technologies and Applications*, 4, 123-140.

COHEN, Y., VITNER, G. e SARIN, S. (2008), Work allocation to stations with varying learning slopes and without buffers, *European Journal of Production Research*, 184, 797-801.

COOK, J.A. (1991), Competitive Model of the Japanese Firm, *Journal of Policy Modeling*, 13, 93-114.

COROMINA, A., OLIVELLA, J. e PASTOR, R. (2010), A model for the assignment of a set of tasks when work performance depends on experience of all tasks involved, *International Journal Production Economics*, 126, 335-340.

FÁVERO, L.P., BELFIORE, P., DA SILVA, F.L. e CHAN, B.L. *Análise de Dados*, Campus: Rio de Janeiro, 2009.

MAZUR, J.E. e HASTIE, R. (1978), Learning as Accumulation: a Reexamination of the Learning Curve, *Psychological Bulletin*, 85, 1256-1274.

NEMBARD, D.A. e UZUMERI, M.V. (2000), Experimental learning and forgetting for manual and cognitive tasks, *International Journal of Industrial Ergonomics*, 25, 315-326.

NGWENYAMA, O., GUERGACHI, A. e MCLAREN, T. (2007), Using the learning curve to maximize IT productivity: A decision analysis model for timing software upgrades, *International Journal of Production Economics*, 105, 524-535.

PROCHNO, P. (2004), Learning Curve? Which One?, *Brazilian Administration Review*, 1, 53-66.

PRUETT, M. e THOMAS, H. (2008), Experience-based learning in innovation and production, *R&D Management*, 38, 141-153.

ROHRBACH, A. (1927), Economical production of all-metal airplanes and seaplanes, *Journal of the Society of Automotive Engineers*, 20, 57-66.

TEPLITZ, C.J. *The Learning Curve Deskbook: A reference Guide to Theory, Calculations and Applications*, Quorum Books: New York, 1991.



TOKSARI, M.D., ISLEYEN, S.K., GÜNER, E. e BAYKOÇ, O.F. (2008), Simple and U-type line balancing problems with a learning effect, *Applied Mathematical Modeling*, 32, 2954-2961.

UZUMERI, M. e NEMBHARD, D. (1998), A Population of Learners: A New Way to Measure Organizational Learning, *Journal of Operations Management*, 16, 515-528.

WRIGHT, T.P. (1936), Factors Affecting the Cost of Airplanes, *Journal of the Aeronautical Sciences*, 3, 122-128.