



ANÁLISE QUANTITATIVA DA IMPLEMENTAÇÃO DO SISTEMA *LAST PLANNER®* NO BRASIL

Rodrigo Cremonesi Bortolazza (1); Dayana Bastos Costa (2); Carlos Torres Formoso

(1) Universidade Federal do Rio Grande do Sul (UFRGS), Av. Osvaldo Aranha, 99, 3º andar, fone:
+55 51 3316 3959

e-mail: bortolazza@cpgec.ufrgs.br

(2) UFRGS, e-mail: dayana@cpgec.ufrgs.br

(3) UFRGS, e-mail: formoso@ufrgs.br

RESUMO

No Brasil, o sistema de Planejamento e Controle da Produção *Last Planner®* tem sido implementado desde 1996 em um grande número de canteiros de obra. Contudo, estudos até então desenvolvidos se baseavam principalmente na análise qualitativa dos dados, apoiados por poucos estudos de caso.

O presente trabalho descreve um estudo no qual foi desenvolvida uma base de dados constituída por 91 obras, que foram utilizados pelo NORIE para estudos anteriores ou adquiridos junto a empresas que vêm sistematicamente coletando dados de Planejamento e Controle da Produção. Inicialmente, essa amostra foi caracterizada através de uma análise estatística considerando o PPC médio durante a obra. Posteriormente, técnicas de Mineração de Dados (como as árvores de decisão) foram empregadas para a busca de padrões, relacionando esse PPC com a causa do não cumprimento das atividades.

Resultados preliminares das causas do não cumprimento dos pacotes de trabalho indicam que em muitos casos existe uma limitação na implementação do planejamento de Médio Prazo. Além disso, nas árvores de decisão o problema raiz apontado para classificar uma obra com o PPC médio entre alto, médio ou baixo foi o projeto, responsável na estatística descritiva por apenas 3% das ocorrências.

ABSTRACT

In Brazil, the Last Planner System™ has been implemented since 1996 in a large number of construction sites. However, most research studies developed so far have emphasized the analysis of qualitative data, based on single or on a small number of case studies.

A database was built including data from 91 projects, which have been investigated in previous research projects at the NORIE or with some companies that have been collected planning and control indicators. In the beginning, the average PPC (percentage of plans completed) indicator was analyzed for all those projects. After that, Data Mining tools (like decision trees) were used for pattern matching, concerning these PPCs with causes for non completion of work packages.

Preliminary results on the causes for non-completion of work packages indicate that most projects still have limited success in the implementation of look-ahead planning. Moreover, the root node of the decision tree is the “design”, responsible for only 3% of the overall occurrences.

Palavras-chave: indicadores, padrões de comportamento, mineração de dados, PCP

1. INTRODUÇÃO

O sistema de Planejamento e Controle da Produção (PCP) *Last Planner*® vem sendo implementado, desde 1992, em um grande número de empreendimentos e em diversos países (BALLARD; HOWELL, 2003). No Brasil, os primeiros estudos de caso envolvendo essa sistemática são de 1996 e, desde então, diversos trabalhos investigaram a sua implementação (OLIVEIRA, 1999; BERNARDES, 2001; SOARES, 2003). Entretanto, muitas dessas aplicações se basearam em análises qualitativas, apoiadas em um pequeno número de estudos de caso. Assim, percebe-se a oportunidade de aprendizado com a implementação do sistema *Last Planner*®, através do uso dessas referências disponíveis dos estudos de caso anteriores. Além disso, existe a possibilidade do uso de dados coletados em empresas que adotaram essa ferramenta de controle nos últimos anos.

Estudos internacionais já ressaltaram a importância das análises quantitativas para a avaliação do sistema de PCP. Segundo Ballard (2000) é necessário quantificar e entender os benefícios da maior confiabilidade no planejamento quando comparado à segurança, qualidade, prazo e custo.

Os principais dados coletados que dizem respeito ao sistema de PCP *Last Planner*® são o Percentual do Planejamento Concluído (PPC) e as causas do não cumprimento dos pacotes de trabalho. Ambos podem ser considerados indicadores de processo, por fornecer informações pró-ativas aos envolvidos que podem usá-las para prever o desempenho das atividades a serem medidas (ALÁRCON, 2001). Além desses indicadores, existem outros dados quantitativos e também qualitativos para os estudos considerados.

Por outro lado, uma grande quantidade de dados pode esconder informações úteis e uma das ferramentas que vem sendo amplamente utilizada para extrair informações ou conhecimento é a técnica de Mineração de Dados. Essa técnica tem sido usada em diferentes aplicações como controle da produção, análise de mercado e projetos de engenharia, procurando descobrir padrões interessantes (HAN; KAMBER, 2001).

Dessa forma, esse artigo descreve os resultados preliminares de um estudo exploratório de Mineração de Dados referente à implementação do sistema *Last Planner*® pela análise de uma amostra com diferentes empreendimentos. Esse processo tem como objetivo a identificação de padrões interessantes de comportamento na evolução do sistema *Last Planner*® em três diferentes setores do mercado identificados (obras industriais/comerciais para clientes privados, incorporações residenciais e habitações de interesse social). Essa amostra dos empreendimentos foi inicialmente caracterizada através de uma análise estatística descritiva. Foram também utilizadas técnicas de Mineração de Dados para a busca de padrões interessantes entre os valores do PPC médio da obra e as causas de não cumprimento das atividades. Os dados usados nessa investigação vêm de um banco de dados de 91 empreendimentos obtidos de empresas envolvidas em diversos projetos de pesquisa desenvolvidos pelo Núcleo Orientado para a Inovação da Edificação (NORIE) da Universidade Federal do Rio Grande do Sul (UFRGS).

Esse estudo faz parte do projeto SISIND-NET, desenvolvido pelo NORIE/UFRGS em parceria com o Sindicato da Indústria da Construção Civil do Rio Grande do Sul (SINDUSCON/RS) e apoiado pelo Conselho Nacional do Desenvolvimento Científico e Tecnológico (CNPQ). Compreende o desenvolvimento e implementação de um sistema de indicadores de desempenho para *benchmarking* em empresas de construção. Um dos objetivos é o desenvolvimento de um sistema computacional *on line* para o ingresso e disseminação dos dados, incluindo um tutorial para o treinamento. No presente momento existem 18 empresas envolvidas nessa iniciativa (COSTA et al., 2004).

2. MINERAÇÃO DE DADOS

A Mineração de Dados refere-se à extração ou “mineração” de conhecimento à partir de grandes quantidades de dados (HAN; KAMBER, 2001). Muitas pessoas aceitam o uso dessa expressão como um sinônimo para *Knowledge Discovery in Databases* (KDD). Por esse motivo, o termo Mineração de Dados é mais popular do que o próprio KDD. Assim, nesse artigo o termo Mineração de Dados refere-se ao processo que inclui as seguintes etapas: “limpeza”, integração, seleção, transformação e “mineração” dos dados, avaliação de padrões e apresentação do conhecimento (HAN; KAMBER, 2001).

A Mineração de Dados envolve a integração de técnicas de várias disciplinas como aprendizagem de máquina, inteligência artificial, reconhecimento de padrões, estatística e banco de dados buscando

automaticamente extrair conceitos, inter-relações e padrões de interesse em grandes bases de dados (SOIBELMAN; KIM, 2002).

Os bancos de dados também são ricas fontes de informações ocultas que podem ser usadas para a tomada de decisões gerenciais. Nesse sentido, classificação e previsão são tipos de análises usadas para caracterizar classes de dados ou para prever tendências (HAN; KAMBER, 2001).

Um algoritmo utilizado para aprendizagem, que se caracteriza por ser simples e bem sucedido para a classificação e previsão é a árvore de decisão. Essa técnica toma como entrada um objeto ou situação descrita por uma série de atributos e retorna uma decisão. Isso é obtido através de uma seqüência de testes em que cada nó interno corresponde a um teste do valor de uma das propriedades e as ramificações à partir do nó são identificadas com os possíveis valores do teste (RUSSELL; NORVIG, 2004).

Para Han e Kamber (2001) os atributos que não foram considerados para a montagem da árvore de decisão são supostamente irrelevantes. A análise de dados com o objetivo de remover atributos irrelevantes ou redundantes no processo de aprendizado é conhecido como “*feature selection*”. Um exemplo de aplicação é a remoção de atributos que não tenham sido incluídos na árvore de decisão na ocasião da construção de uma Rede Neural Artificial (RNA). Essa remoção de atributos visa a redução da taxa de erro da RNA quando comparada a sua aplicação inicial que considerava o uso de todos os atributos.

Outra técnica para a Mineração de Dados utilizada nesse artigo foi a RNA, que pode ser definida como uma série de unidades conectadas de entrada/saída, em que cada conexão é associada a um peso. Na fase de aprendizagem, os pesos são ajustados para prever a classificação correta de acordo com as entradas. As vantagens da rede neural são: a alta tolerância aos dados que apresentem qualquer espécie de “ruído” e a habilidade para classificar padrões a que não tenha sido treinada (HAN; KAMBER, 2001). Redes neurais são boas em aplicações em que os dados não podem ser representados simbolicamente como, por exemplo, o reconhecimento de voz e interpretação de dados de sinais de instrumentos científicos (WATSON, 1997).

Entretanto, as RNA são criticadas pela dificuldade na interpretação, já que é muito difícil entender o significado dos pesos resultantes. Uma rede neural funciona como uma “caixa preta”, porque não são fornecidas explicações ou justificativas no sistema (WATSON, 1997). Por essa razão, muitas pesquisas têm sido desenvolvidas para a extração de conhecimento de redes neurais, representando-as apenas simbolicamente como, por exemplo, para a extração de regras ao invés de simplesmente apresentar o resultado (HAN; KAMBER, 2001). Isso limita suas aplicações. Na Europa, por exemplo, é ilegal a um banco recusar o crédito de um cliente sem explicações a respeito da decisão. Por esse motivo, essa técnica não poderia explicar como essa decisão foi obtida (WATSON, 1997).

Esse estudo utilizou a técnica da árvore de decisão porque é um algoritmo de aprendizagem simples e de grande sucesso (RUSSELL; NORVIG, 2004). Além disso, as redes neurais foram utilizadas para permitir a comparação entre os resultados nos conjuntos de teste utilizando as duas técnicas.

3. MÉTODO DE PESQUISA

Inicialmente foi construída uma base de dados com 124 empreendimentos, à partir de dados com diferentes origens. Alguns deles foram obtidos junto a dissertações de mestrado ou teses de doutorado em estudos anteriores no NORIE/UFRGS. Outros dados foram obtidos de empresas que mantêm o uso do sistema *Last Planner*® nos últimos anos. Esses projetos ocorreram entre os anos de 1996 e 2005.

Inicialmente, a amostra foi dividida em grupos. Dessa forma, se procurou caracterizar três setores do mercado (obras industriais/comerciais para clientes privados, incorporações residenciais e habitações de interesse social). A amostra inicial tinha 124 empreendimentos. Contudo, 9 deles foram excluídos uma vez que eles foram coletados em um período inferior a quatro semanas ou apresentaram o PPC médio de 100%, descumprindo as condições mínimas para a inclusão no banco de dados. Posteriormente, na etapa de validação de dados obtidos junto às empresas excluiu-se mais 24 obras, uma vez que as mesmas já não possuíam os registros que confirmassem os valores enviados.

Na amostra restante o número de semanas dos projetos analisados oscilou entre 4 e 107 semanas. Em 51 deles, as causas do não cumprimento dos pacotes de trabalho também foram investigadas. Para tanto, agrupou-se as mesmas em 8 categorias: (1) mão-de-obra, (2) materiais, (3) equipamentos, (4)

projeto, (5) planejamento, (6) clientes, (7) chuva e (8) fornecedores. As causas de não cumprimento também foram classificadas em problemas internos (mão-de-obra, materiais, equipamentos, projeto, planejamento) ou externos (clientes, chuva e fornecedores).

No início, usou-se a estatística descritiva para caracterizar a amostra, relacionando sua tendência central e a dispersão dos dados (HAN; KAMBER, 2001). Para a tendência central, a mediana foi adotada por representar melhor a situação real da construção e por ter o efeito de filtrar dados discrepantes, que poderiam estar incluídos no cálculo da média (RAMÍREZ et al., 2004). Relacionado à dispersão dos dados, as medidas mais usadas são: quartis, *outliers* e variância. O primeiro quartil (Q1) é o 25º percentil (1/4 dos valores estão abaixo dele), a mediana corresponde ao 50º percentil e o terceiro quartil (Q3) é o 75º percentil (3/4 dos valores estão abaixo dele). Assim sendo, a distribuição foi representada pelas seguintes medidas: mínimo, Q1, mediana, Q3 e máximo. Além disso, o desvio padrão e o coeficiente de variação também foram usados como medidas de dispersão.

Foram utilizadas as técnicas de árvore de decisão e RNA para a busca de padrões do PPC médio com a causa do não cumprimento dos pacotes de trabalho. Pela classificação, o PPC foi dividido em três grupos ($PPC < 70\%$, $70\% \leq PPC < 80\%$ e $PPC \geq 80\%$). Existem 6 empreendimentos no primeiro grupo, 23 no segundo e 22 no terceiro. Se a mediana do PPC fosse usado no lugar do PPC médio do empreendimento analisado os grupos seriam os mesmos. Por essa razão, o PPC médio foi utilizado, uma vez que essa denominação é mais amplamente utilizada.

Resultados preliminares usando árvores de decisão ou RNA no presente banco de dados apresentaram grandes taxas de erro. Por essa razão, duas formas na entrada de dados relacionadas com as causas de não cumprimento dos pacotes de trabalho foram consideradas: (1) a taxa entre o número de problemas e o número total de semanas durante a avaliação (média dos problemas, que aparece na tabela 3) e (2) o percentual de problemas durante a avaliação (também na tabela 3).

Duas amostras foram necessárias para aplicações das árvores de decisão ou das RNA: (a) conjunto de treino e (b) conjunto de teste. No conjunto de treino, 36 obras foram usadas, incluindo os valores extremos para evitar discrepâncias na realização do teste da amostra reservada para essa finalidade. O conjunto de teste tinha 11 obras, selecionadas para refletir a distribuição dos diferentes grupos do conjunto de treino. Foi usado o mesmo conjunto de teste na árvore de decisão e na RNA, para permitir a comparação dos resultados.

O software utilizado foi o *Weka*ⁱⁱ, na medida em que o mesmo permite a construção tanto de uma árvore de decisão quanto de uma rede neural artificial. Referente à RNA, no início a taxa de erro foi muito alta, já que todos os atributos disponíveis foram utilizados. Nessa ocasião, a árvore de decisão foi construída com o objetivo de escolher os atributos mais relevantes. Após a construção dessa árvore, uma nova rede neural foi construída com os atributos selecionados e, como resultado, a taxa de erro foi muito menor quando comparada à taxa de erro inicial.

4. RESULTADOS PRELIMINARES

Essa seção apresenta alguns resultados preliminares desse projeto de pesquisa. A figura 1 apresenta os dados de PPC, incluindo o mínimo, Q1, mediana, Q3 e máximo, enquanto que a tabela 1 apresenta a média, desvio padrão, coeficiente de variação e o tamanho da amostra para cada grupo de projetos. As figuras 2 e 3 são histogramas comparando o PPC com o seu número de ocorrências.

De acordo com a figura 1, os valores de Q1 e Q3 estão próximos da mediana. Esse resultado pode ser melhor visualizado no histograma da figuras 2. A boa distribuição ao redor da mediana não é observada na amostra das habitações de interesse social (figura 3). Nessa amostra, os valores significativos do PPC médio encontram-se ao redor de dois valores (50% e 75%). Essa alta dispersão dos dados é corroborada pelo maior desvio padrão e coeficiente de variação (CV) nessa amostra (tabela 1). Analisando-se mais a fundo essas causas percebe-se que a principal razão para esse reduzido PPC é o fato de que o planejamento de médio prazo com toda a sua análise de restrições não está completamente implementado nesses projetos.

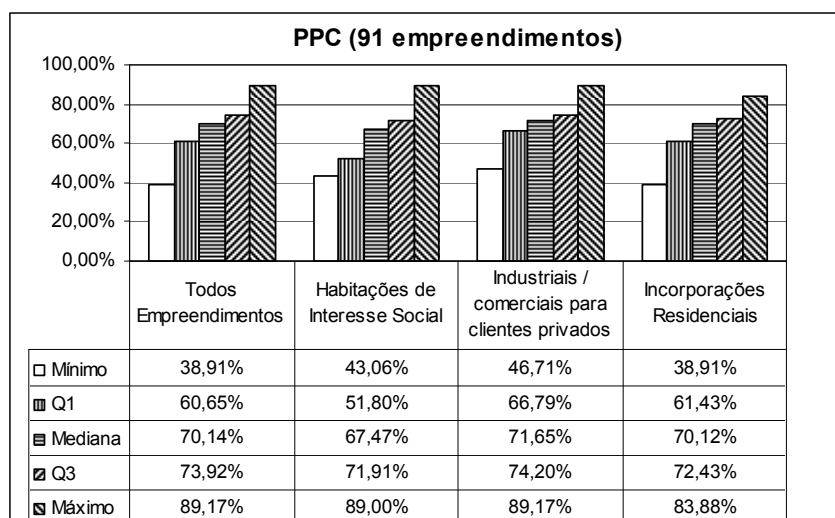


Figura 1: Dispersão do PPC médio na amostra de 91 empreendimentos

Tabela 1 - Outras análises estatísticas na amostra de 91 empreendimentos

	Todos Empreendimentos	Habitações de Interesse Social	Industriais / comerciais para clientes privados	Incorporações Residenciais
Média	68,10%	64,80%	68,92%	72,69%
Desvio Padrão	10,46%	13,76%	8,48%	5,16%
CV	15,36%	21,24%	12,30%	7,10%
Amostra	57	20	27	10




Figura 2: Histograma do PPC médio de todos os empreendimentos

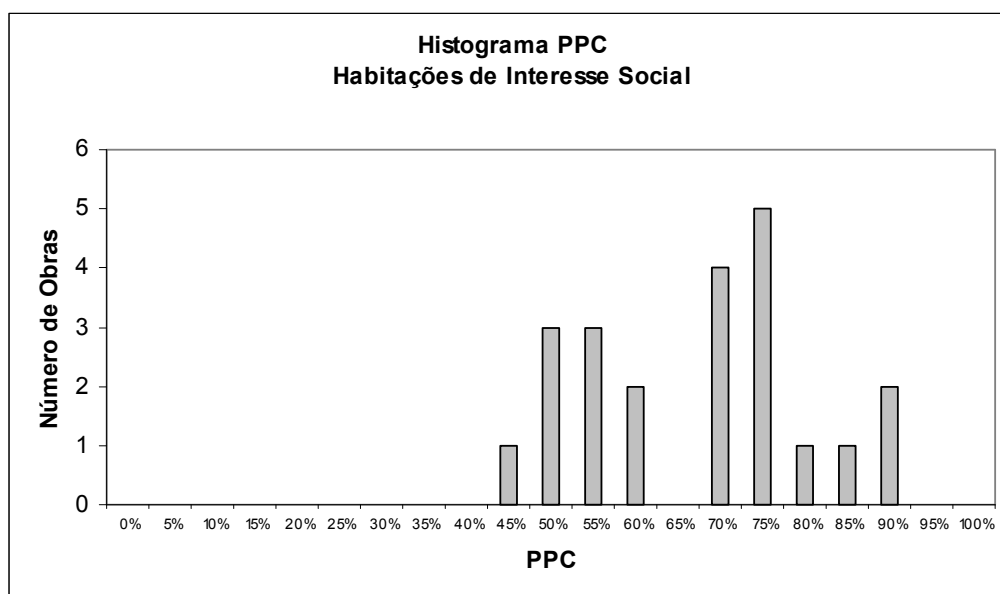


Figura 3: Histograma do PPC médio das habitações de interesse social

Em 51 empreendimentos, foram investigadas as causas do não cumprimento dos pacotes de trabalho. A porcentagem da causa do não cumprimento dos pacotes de trabalho encontra-se na figura 5. Na tabela 2 há uma descrição dos problemas para cada um dos segmentos do mercado.

Através da figura 4, identifica-se que os problemas mais importantes estão relacionados à mão-de-obra e falhas no planejamento. Esses problemas também foram observados nos três setores do mercado (tabela 2). Entretanto, mão-de-obra e planejamento podem ser categorias muito abrangentes, impedindo uma classificação mais precisa. Por esse motivo, é necessária uma maior investigação na busca das causas reais do não cumprimento dos pacotes de trabalho.

Baseado na grande incidência de certas classes de problemas é fundamental a melhoria do planejamento de médio prazo, procurando identificar as restrições relacionadas a mão-de-obra e planejamento, aumentando, assim, a probabilidade de conclusão dos pacotes de trabalho no planejamento de curto prazo.

Geralmente, quando não existe um sistema de PCP, as causas externas (como condições meteorológicas) são apontadas como a maior fonte de atrasos. Entretanto, somando-se os três grupos de problemas relacionados às causas externas (clientes, condições meteorológicas e fornecedores) identificadas na amostra, observa-se que a ocorrência é inferior a 20% do total de problemas (17,5% na amostra total, 18,0% nas habitações de interesse social, 19,7% nas obras industriais / comerciais para clientes privados e 12,4% nas incorporações residências).

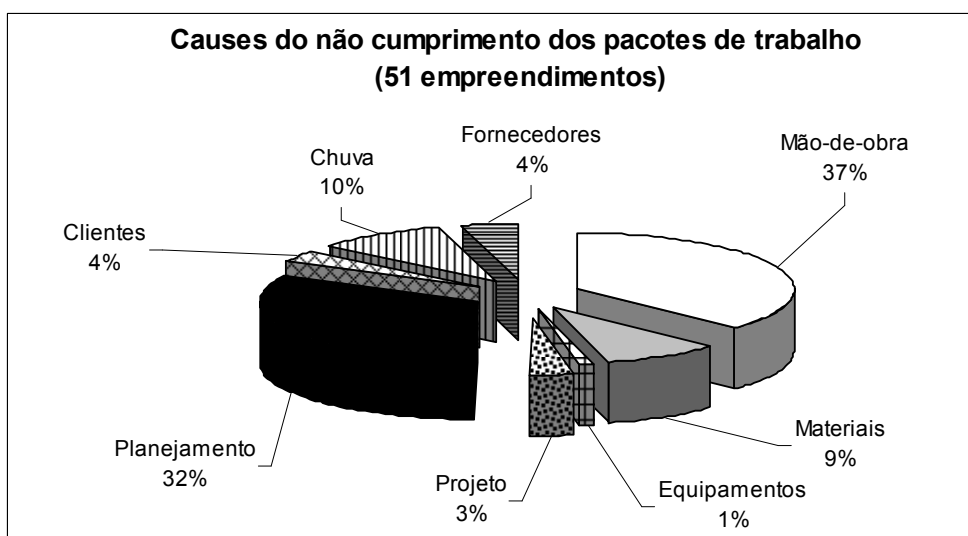


Figura 4: Causa do não cumprimento dos pacotes de trabalho em 51 empreendimentos

Tabela 2 - Causas do não cumprimento dos pacotes de trabalho em 51 empreendimentos relacionado aos setores do mercado

	Todas Obras	Habitacões de Interesse Social	Industriais / comerciais para clientes privados	Incorporacões Residenciais
Mão-de-obra	37,12%	48,52%	30,61%	41,31%
Materiais	8,63%	7,93%	8,18%	10,16%
Equipamentos	1,30%	0,71%	1,31%	1,76%
Projeto	3,19%	0,12%	3,97%	4,10%
Planejamento	32,28%	24,73%	36,21%	30,27%
Clientes	3,52%	0,00%	6,50%	0,20%
Chuva	9,80%	14,20%	8,79%	8,30%
Fornecedores	4,17%	3,79%	4,44%	3,91%

As taxas de erro na amostra de teste foram muito altas. Por esse motivo, avaliou-se a mudançã no formato de entrada dos dados, buscando aumentar a confiabilidade da aplicacão. No banco de dados existiam informacões do PPC ao longo das semanas em cada um dos empreendimentos e o número total das causas do não cumprimento dos pacotes de trabalho. Por esse motivo, dois formatos na entrada dos dados foram avaliados. A coluna **Média dos Problemas** indica que o número total de ocorrências da causa do não cumprimento das atividades foi dividido pelo número de semanas. A coluna **Percentual dos Problemas** é o percentual de cada um dos grupos de problemas em cada empreendimento. Os principais resultados relacionados ao uso das técnicas de Mineraçã de Dados (as taxas de erro dessas técnicas) estão apresentados na tabela 3.

Entre as árvores de decisão apontadas na tabela 3, a mais interessante é mostrada na figura 6. Ela possui o formato de entrada dos dados seguindo o padrão previamente utilizado na estatística descritiva (percentual de problemas no lugar da média dos problemas). Nessa aplicacão, são procuradas relações entre o percentual de problemas identificados e os grupos de PPC médio dos empreendimentos.

Tabela 3 – Taxa de erro na amostra de teste da árvore de decisão e da RNA considerando dois formatos na entrada dos dados

Ferramentas de mineração de dados	Formato na Entrada dos Dados	
	Média dos Problemas	Percentual dos Problemas
Árvore de decisão	33,33%	33,33%

Ferramentas de mineração de dados	Formato na Entrada dos Dados	
	Média dos Problemas	Percentual dos Problemas
RNA	53,33%	46,67%
RNA com atributos da árvore de decisão	33,33%	44,44%

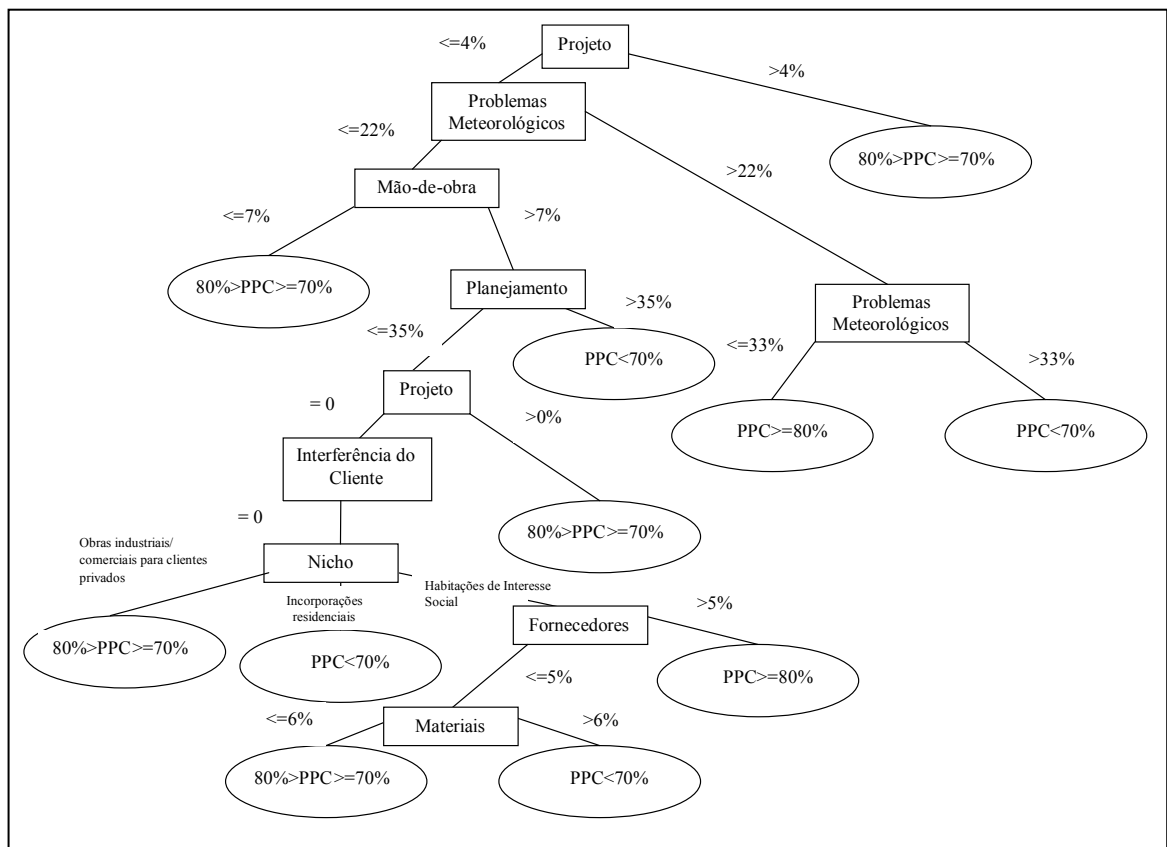


Figura 5: Árvore de decisão usando como atributos de entrada o percentual dos problemas e classificando de acordo com o PPC médio

Com relação a figura 5, os resultados da árvore de decisão mostram que entre os atributos considerados na classificação, o mais relevante (projeto) foi escolhido como o nó raiz. É a partir desse ponto que a árvore cresce, de cima para baixo. Os resultados são os vários nós conectados por ramos. Cada nó interno na árvore corresponde ao teste de valor de uma das propriedades e os galhos de um nó são nomeados com os possíveis valores do teste. Os “nós ao final dos galhos são chamados nós de folha”. Esse nó tem um papel especial se a árvore for analisada para previsão (RUSSELL; NORVIG, 2003 e SOIBELMAN; KIM, 2002).

A vantagem de usar técnicas como a árvore de decisão é tornar explícito alguns padrões não reconhecidos entre os atributos. Na árvore de decisão descrita na figura 5, o projeto foi selecionado como o nó raiz. Naturalmente, é conhecida a influência do projeto no comprometimento do planejamento. Entretanto, isso representa apenas 3,19% dos problemas na análise estatística descritiva.

Na presente amostra não existem relações claras entre o não cumprimento dos pacotes de trabalho e os grupos de PPC médio. Os altos valores das taxas de erro como ferramenta de previsão podem ser atribuídas ao tamanho reduzido e a heterogeneidade da amostra (diferentes empreendimentos, setores de mercado com características distintas, canteiros de obra em fases de implementação diversos e localizados até mesmo em cidades diferentes). Além disso, não é possível avaliar a qualidade e a padronização da informação fornecida por esses projetos, porque o processo de implementação e a forma como os dados foram coletados são diferentes entre os projetos. Por exemplo, em alguns empreendimentos a implementação do *Last Planner*® foi supervisionada pelos pesquisadores.

De acordo com a tabela 3, as taxas de erro nas redes neurais usando a árvore de decisão como “*feature selection*” são menores. No melhor resultado, a redução da taxa de erro fica ao redor de 38%. A alta taxa de erro indica que essa aplicação não é confiável na previsão de padrões. Por essa razão, maiores investigações são necessárias, levando em conta outras características que são melhor relacionadas ao PPC (como desvios de custo e de prazo).

Referente ao tamanho da base de dados, está claro que o tamanho reduzido não é suficiente para encontrar padrões interessantes e consistentes, devido ao fato de que a amostra é muito heterogênea. Por esse motivo, é necessário procurar por padrões em uma maior quantidade de dados em pesquisas futuras.

Outro fator importante na coleta de PPC e causa do não cumprimento das atividades é o uso de uma base de dados estruturada seguindo critérios padronizados. Isso pode ser alcançado a partir dos dados fornecidos pelas empresas que estão participando do Clube de *Benchmarking* do Projeto Sisind-NET apoiado por um sistema de informação do *Last Planner*® como o *Power Project Control* (<http://www.gepuc.cl/fdi>), desenvolvido pelo GEPUC (Programa de Excelência em Gestão da Produção da Pontifícia Universidade Católica do Chile).

5. ESTUDOS FUTUROS

Como indicações de trabalhos futuros as relações entre medidas de desempenho podem ser analisadas com o uso dos dados coletados dos vários projetos, relacionando o impacto do sistema *Last Planner*® à medição de desempenho. Por exemplo, a medida PPC pode ser comparada a indicadores de processo relacionados ao desvio de prazo e de custo.

Esses dados também podem ser apoiados por informações qualitativas, como o *checklist* usado por Bernardes (2001) com o objetivo de avaliar as boas práticas observadas durante a implementação do *Last Planner*®.

Outra possibilidade é a pesquisa de padrões interessantes na evolução do PPC. Resultados prévios apontaram que as causas externas do não cumprimento dos pacotes de trabalho podem aumentar ao longo do projeto (BALLARD; HOWELL, 1997).

Até agora, os dados foram coletados de pesquisas prévias ou com empresas que adotaram o *Last Planner*® como ferramenta de controle por vários anos. Entretanto, informações adicionais são necessárias, especialmente relacionadas às características dos empreendimentos, medidas do grau de complexidade e incerteza dessas construções e satisfação geral do cliente. Por essa razão, é necessário o uso de questionários e entrevistas para a coleta de dados com o objetivo de uma análise mais aprofundada desses empreendimentos. A última parte desse projeto de pesquisa é a validação em estudos de caso, identificando as diretrizes para aumentar a qualidade dos dados coletados.

6. COMENTÁRIOS FINAIS

Até o presente momento, estudos relacionados ao *Last Planner*® focaram suas análises em métodos de estatística descritiva. Por esse motivo, as causas do não cumprimento dos pacotes de trabalho identificados foram imediatamente apontadas como as principais responsáveis pelo baixo desempenho. Entretanto, esse tipo de análise não provém informações quanto ao relacionamento entre os diferentes atributos. Essas informações podem ser exploradas através do uso de ferramentas de Mineração de Dados para a descoberta de conhecimento a partir das bases de dados, como a árvore de decisão e a RNA.

Entretanto, nesse artigo a árvore de decisão e a rede neural artificial não apresentaram as conclusões finais devido às altas taxas de erro, ao tamanho reduzido e à heterogeneidade da amostra. Esses

resultados indicam a necessidade de uma maior base de dados, assim como investigar formas de melhorar o processo de coleta de dados (mais estruturado e padronizado, com características relevantes), objetivando a melhoria da confiabilidade e da qualidade da informação.

7. AGRADECIMENTOS

Esse projeto de pesquisa foi possível com o apoio financeiro da CAPES (Coordenação para o Aperfeiçoamento de Pessoal de Ensino Superior) e CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico).

8. REFERÊNCIAS BIBLIOGRÁFICAS

ALARCÓN, L.F.; GRILLO, A.; FREIRE, J.; DIETHELM, J. Learning from collaborative benchmarking in the construction industry. In: ANNUAL CONFERENCE ON LEAN CONSTRUCTION, 9, 2001, Cingapura. **Proceedings...** Cingapura: 2001. Disponível em: <<http://cic.vtt.fi/lean/singapore/Alarconet.pdf>>. Acesso em: 15 nov. 2004.

BALLARD, G. **The Last Planner System of Production Control**. 2000. Thesis (Doctor of Philosophy) - School of Civil Engineering, Faculty of Engineering. University of Birmingham, Birmingham.

BALLARD, G.; HOWELL, G.A. An update on last planner. In: ANNUAL CONFERENCE ON LEAN CONSTRUCTION, 11, 2003, Blacksburg. **Proceedings...** Blacksburg: 2003. Disponível em: <<http://strobos.cce.vt.edu/IGLC11/PDF%20Files/08.pdf>>. Acesso em: 15 nov. 2004.

BALLARD, G.; HOWELL, G. **Shielding Production: an essential step in production control**. California: Construction Engineering and Management Program, Department of Civil and Environmental Engineering, University of California, 1997. (Technical Report 97-1)

BERNARDES, M.M.S. **Desenvolvimento de um Modelo de Planejamento e Controle da Produção para Micro e Pequenas Empresas de Construção**. 2001. Tese (Doutorado em Engenharia Civil) - Curso de Pós-Graduação em Engenharia Civil. Universidade Federal do Rio Grande do Sul, Porto Alegre.

COSTA, D.B et al. Performance measurement systems for benchmarking in the brazilian construction industry. In: CIB W107, 2004, Tailândia. **Proceedings...** Pathum Thani, 2004.

HAN, J.; KAMBER, M. **Data Mining: concepts and techniques**. Estados Unidos: Morgan Kaufmann Publishers, 2001.

OLIVEIRA, K.A.Z. **Desenvolvimento e Implementação de um Sistema de Indicadores no Processo de Planejamento e Controle da Produção: proposta baseada em estudo de caso**. 1999. Dissertação (Mestrado em Engenharia Civil) – Curso de Pós-Graduação em Engenharia Civil. Universidade Federal do Rio Grande do Sul, Porto Alegre.

RAMÍREZ, R.R.; ALARCÓN, L.F.C.; KNIGHTS, P. Benchmarking System for Evaluating Management Practices in the Construction Industry. **Journal of Management in Engineering**, EUA, v.20, n.3, p.110-117, jul. 2004.

RUSSELL, S.; NORVIG, P. **Inteligência Artificial**. Tradução da 2. ed. Rio de Janeiro: Elsevier Editora Ltda, 2004.

SOARES, A.C. **Diretrizes para a manutenção e o aperfeiçoamento do processo de planejamento e controle da produção em empresas construtoras**. 2003. Dissertação (Mestrado em Engenharia Civil) – Curso de Pós-Graduação em Engenharia Civil. Universidade Federal do Rio Grande do Sul, Porto Alegre.

SOIBELMAN, L.; KIM, H. Data preparation process for construction knowledge generation through knowledge discovery in databases. **Journal of Computing in Civil Engineering**, EUA, v. 16, n. 1, p.39-48, jan. 2002.

WATSON, I. **Applying Case-Based Reasoning: Techniques for Enterprise Systems**. Estados Unidos: Morgan Kaufmann Publishers, 1997.

ⁱ Os termos *Last Planner* e *Last Planner System* são marcas registradas do *Lean Construction Institute*.

ⁱⁱ O freeware *Weka* pode ser obtido na página: <http://www.cs.waikato.ac.nz/~ml/weka/>