

バイクシェアシステムにおけるトリップ予測

Trip Prediction in Bike Sharing Systems

大川 真耶^{*1}

Maya Okawa

倉島 健^{*1}

Takeshi Kurashima

田中 佑典^{*1}

Yusuke Tanaka

戸田 浩之^{*1}

Hiroyuki Toda

^{*1}日本電信電話株式会社

NTT Service Evolution Laboratories

Trip demand prediction plays a crucial role in bike-sharing systems. Predicting trip demand is a highly challenging problem because it is influenced by multiple factors, such as periodic changes, correlation between stations, weather and types of users. Although several recent studies successfully address some of these factors, no framework exists that can consider all of them simultaneously. To this end, we develop a novel form of the point process that jointly incorporates all the above factors to predict trip demand, i.e., predicting the number of pick-up and drop-off events in the future and when over-demand is likely to occur. Our extensive experiments on real-world bike sharing systems demonstrate the superiority of our trip demand prediction method over five existing methods.

1. はじめに

シェアリングエコノミーの拡大に伴って、自転車シェアリングサービス（以下、「バイクシェアシステム」）が世界各国で増加している。バイクシェアシステムは自転車をユーザ同士でシェアし、必要な時に自由に使うシステムである。ユーザは街中に設置されている自転車駐輪ポート（以下、「ステーション」）から任意のタイミングで自転車を借り、任意のステーションに返却することができる。これらのシステムは市民にとってのアクセシビリティの向上、自動車交通からの転換による混雑・環境問題の緩和が見込めるという利点から従来の公共交通サービスに代わる新たな短距離移動手段として期待を集めている[2]。複数の都市でバイクシェアシステムにおけるトリップデータをオープンデータとして公開する試みが始まっている[9]。トリップデータは出発ステーション、出発時刻と到着ステーション、到着時刻の情報に加え、会員種別（会員・非会員）、年齢、性別、住所等ユーザに関する情報を含む。トリップデータの分析・予測はシステムの最適化を行う上で非常に重要な役割を持つ。例えば、いつどこで何台の自転車が必要になるかを予測できれば、事前に適切な配置を行うことで自転車の供給不足を防ぐことができる。

バイクシェアシステムにおけるトリップ予測手法は多数存在する。初期の研究では、ARMA[5]等の時系列モデル、隠れマルコフモデル[10]、ベイジアンネットワーク[4]等直近の需要の変化に基づいて未来のトリップ需要を予測する手法が用いられてきた。最近の研究では周期性を考慮した手法が高い予測性能を示すことが確かめられている[1]。例えば周期性に基づく非一様点過程モデルがRamonら[1]によって提案されている。天気がトリップ需要の変化に大きな影響を与えるという結果も複数の研究で報告されている[11, 13, 7]。Yangら[13]やLiuら[7]は周期と天気に加え出発ステーションと到着ステーションの関係を考慮した手法を構築した。しかし、これらの手法は個々のトリップに付随するユーザ属性を考慮できないという大きな問題がある。これらの要素によってトリップ需要の変動の仕方が大きく異なるということが基礎分析で確かめられている[14]。これらのユーザ属性の適切な利用は、予測精度の向上やトリップ需要変動のさらなる理解に資すると考えられる。

連絡先: 大川真耶, NTT, okawa.maya@lab.ntt.co.jp

そこで本研究では、バイクシェアシステムにおけるトリップデータを対象として、従来手法で考慮していた周期性、天気、出発ステーションと到着ステーションの関係に加え、会員種別等のユーザ属性を考慮し将来の需要予測を行う確率モデルを構築する。具体的には、都市の各ステーションにおける出発・到着を不定時間間隔で起こるイベントとみなし、マーク付き点過程を拡張した手法を用いてこれらのデータを記述する。マーク付き点過程はイベントの系列からなるデータをモデル化するための確率過程の一種であり、購買等の人間行動や地震等の自然現象の統計分析・予測に広く用いられてきた。近年は、point-of-interest(POI)への訪問履歴[6, 3]や地理空間上のある地点から別の地点への移動を表すトリップデータ[12]等移動に関するデータへの適用も広がっている。Wangら[12]は点過程の混合モデルを用いてトリップの目的を推定する技術を提案した。しかし、これらの手法は周期のような長期的な需要変動のパターンや、天気等の行動データに表れない情報を考慮することができない。前節で述べた通り、トリップ需要はこれらの要素の影響で大きく変動する。本稿では、これらの要素の複合的な効果を考慮する新たなマーク付き点過程モデルを構築する。

本研究の貢献は以下の通りである。

- トリップ需要予測のための新たな手法を構築した。提案手法は周期、天気、出発ステーションと到着ステーションの関係に加え会員種別等のユーザ属性を考慮することができる（3章）。
- 3都市で収集されたバイクシェアシステムのトリップデータを用いて実験を行なった。提案手法が既存手法に比べて良い予測性能を持つことを示した（4章）。

2. 問題設定

トリップは出発ステーション u 、到着ステーション v 、出発時刻 t 、トリップ時間（出発から到着までにかかった時間） Δ とユーザ属性（例えば会員種別や年齢、性別） m の5つの要素からなるタプル (u, v, t, Δ, m) で表される。ステーションの集合を $S = \{s_1, \dots, s_K\}$ 、ユーザ属性の集合を M とおく。ここで K はステーションの個数である。あるバイクシェアシステムにおけるトリップの系列 $\mathcal{D} = \{(u_i, v_i, t_i, \Delta_i, m_i)\}_{i=1}^n$ が与え

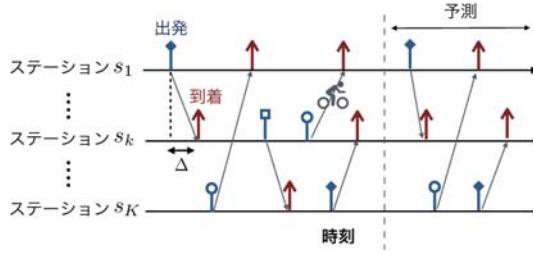


図 1: トリップデータの例. 横軸は各々のステーションにおけるイベントの時間軸を表す.

られたとする. ここで n はトリップ数である. ここで \mathcal{D} の各要素は出発ステーション $u_i \in \mathcal{S}$, 到着ステーション $v_i \in \mathcal{S}$, 出発時刻 $t_i \in \mathbb{R}^+$, トリップ時間 $\Delta_i \in \mathbb{R}^+$ とユーザ属性 m_i からなるイベントとみなすことができる. 図 1 にトリップデータの例を示す. 図 1 中の青線が各ステーションにおける出発イベント, 赤線が到着イベントを表している. 出発イベントのマークは到着ステーションに対応している.

本研究ではトリップデータに加え, 天気データ $\mathcal{W} = \{F_t, H_t, D_t, V_t, R_t\}_{t \in \mathbb{R}^+}$ を用いる. \mathcal{W} の各要素は時刻 t における気温 F_t , 湿度 H_t , 風速 D_t , 視程 V_t , 降水量 R_t からなるタプルである.

本研究ではトリップデータと天気データが与えられた下で未来の任意の時間帯におけるトリップ需要を予測する問題を取り組む. ここでトリップ需要を任意の時間窓における出発イベント数, 到着イベント数で定義する.

3. モデル

3.1 マーク付き点過程

提案手法の導入の前に, まずベースとなるマーク付き点過程について概要を説明する. マーク付き点過程は不等時間隔で起こる現象(イベント)をモデル化する確率過程の一種である. 時刻 t とマーク(例えば到着ステーション等) v からなるイベントを (t, v) とおく. マーク付き点過程はマーク v のイベントが生じる確率的な頻度を表す関数(以下, 「強度関数」) $\lambda(t, v)$ を用いて記述される. 強度関数が $\lambda(t, v) = \lambda(t)f(v|t)$ の形に分解できると仮定する. ここで $f(v|t)$ は時刻 t においてマーク v が発生する条件付き確率, $\lambda(t)$ は単位時間ごとのイベントの発生回数の期待値を表す関数である. N_H 個のイベントからなるイベント履歴 $\mathcal{H} = \{(t_i, v_i)\}_{i=1}^{N_H}$ が与えられた下で, 尤度関数は次式で書き下せる.

$$p(\mathcal{H}|\lambda(t, v)) = \left[\prod_{(t_i, v_i) \in \mathcal{H}} \lambda(t_i)f(v_i|t_i) \right] \exp \left(- \int_0^T \lambda(t) dt \right). \quad (1)$$

3.2 提案手法

本稿では, 過去のトリップデータと天気の情報を用いて未来のトリップ需要を予測する手法を構築する. 具体的には, 各ステーションを出発するトリップの系列と各ステーションペア間のトリップ時間を各々独立な確率過程を用いてモデル化する. ステーション u を出発するトリップの系列 $\mathcal{D}^u = \{(t_i, v_i, m_i, \Delta_i) | u_i = u\}_{i=1}^n$ と各時刻における天気情報 $W_t = (F_t, H_t, D_t, V_t, R_t)$ の集合が与えられたとする. 提案手法の枠組みでは, ステーション u を出発地点とするトリップの集合 $\{(t_i, v_i, m_i) | u_i = u\}_{i=1}^n$ とトリップ時間の系列 $\{\Delta_i | u_i = u\}_{i=1}^n$ を独立にモデル化し, 二つのモデルの推定結果を合わせてトリップ需要(任意の時間窓における出発イベント数と到着イベント数)の予測を行う. 各々のモデルについて以下に述べる.

3.2.1 出発イベントのモデル化

1 章で述べた背景を踏まえ, マーク付き点過程モデルに周期と天気等の外部情報を導入して拡張したモデルを構築する. ステーション u において v を目的地とする出発イベントが時刻 t に起きる率を表す強度関数 $\lambda_u(t, v)$ を時刻 t における天気情報 W_t を使って次式の通りモデル化する.

$$\lambda_u(t, v|W_t) = f_u(v|t)\lambda_u(t|W_t). \quad (2)$$

ここで $\lambda_u(t|W_t)$ はステーション u , 時刻 t における出発イベントの発生率を表す関数, $f_u(v|t)$ はある時刻 t , ステーション u において行き先としてステーション v が選ばれる条件付き確率である.

ステーション v が到着ステーションとして選ばれる確率が曜日や時刻によって周期的に変化するという仮定に基づき $f_u(v|t)$ をモデル化する. まず, 各時刻 t について各週の始めから数えた相対時刻 $d \in [0, 7]$ 日を導入する. 相対時刻 d において行き先としてステーション v が選ばれる確率 $p_u(v|d)$ を Gaussian Naive Bayes (GNB) [8] でモデル化する. 具体的には, ベイズの定理を使って $p_u(v|d)$ を事前分布と尤度の積 $p_u(v|d) \propto p_u(d|v)p_u(v)$ で書き換える. $p_u(d|v)$ のモデル化にはガウス分布, $p_u(v)$ のモデル化には多項分布を用いる. これにより, 曜日と時間帯によるステーション v の行き先としての選ばれやすさの違いを考慮することができる.

$\lambda_u(t|W_t)$ を周期性(要素 1)を表す因子 $\lambda_{u,m}(t)$ と天気(要素 2)の影響を表す因子 $\alpha_{u,m}(W_t)$ の積でモデル化する.

$$\lambda_u(t|W_t) = \sum_{m \in \mathcal{M}} \alpha_{u,m}(W_t) \lambda_{u,m}(t). \quad (3)$$

ここで出発イベントの起りやすさと天気の変化に対する反応がマーク(会員種別や属性等の付加要素)によって異なるという仮定に基づき, マーク m ごとの関数を導入した.

(要素 1) 周期性 1 週間の周期性を考慮するため, $\lambda_{u,m}(t)$ を J 個のガウシアンカーネルの和で定義する.

$$\lambda_{u,m}(t) = \sum_{j=1}^J x_j^{u,m} \exp \left(-\sin^2 \left(\pi \frac{t - \omega_j}{l} \right) / h^2 \right). \quad (4)$$

ここで ω_j は j 番目のガウシアンカーネルの平均, h は標準偏差, l は周期を表すハイパーパラメータである. 本研究では, $J = 168$, $l = 7$ 日, $h = 60$ 分, $\omega_j = j \times 60$ 分とした. $x_j^{u,m}$ はステーション u , m 番目のマークに対応する j 番目のカーネルの重みである. この定式化により, 曜日と時刻ごとの周期性を取り入れることができる.

(要素 2) 天気 天気の変化に対するトリップ需要の非線形な変動を捉えるため, 多項式を用いて $\alpha_{u,m}(W_t)$ をモデル化する.

$$\alpha_{u,m}(W_t) = \exp (\mathbf{a}_{u,m} W_t^T + \mathbf{b}_{u,m} W_t + \epsilon_{u,m}). \quad (5)$$

本稿では簡単のため, 二項式の指數関数でモデル化した. $\mathbf{a}_{u,m}$ と $\mathbf{b}_{u,m}$ は 5 種類の天気情報(気温, 湿度, 風速, 視程, 降水量)に対応する 5 次元の回帰係数のベクトル, $\epsilon_{u,m}$ は切片である.

出発イベントモデルのパラメータセットを $\Psi = \{\{\{x_j^{u,m}\}_{j=1}^J, \beta, \gamma, \mathbf{a}_{u,m}, \mathbf{b}_{u,m}, \epsilon_{u,m}\}\}_{u \in \mathcal{S}, m \in \mathcal{M}}$ とおく.

3.2.2 トリップ時刻のモデル化

ステーション u, v 間のトリップ時間 Δ を対数正規分布でモデル化する. 対数正規分布はトリップ時間のモデル化に一般的に用いられる.

$$p_{u,v}^m(\Delta) = \frac{1}{\Delta \sigma_{uv}^m \sqrt{2\pi}} \exp \left(-\frac{(\log \Delta - \mu_{uv}^m)^2}{2\sigma_{uv}^{m,2}} \right). \quad (6)$$

ここで $\{\mu_{uv}^m, \sigma_{uv}^m\}_{m \in \mathcal{M}, u \in \mathcal{S}, v \in \mathcal{S}}$ はモデルパラメータである。

3.3 学習

出発イベントモデルの対数尤度は次式で書き下せる。

$$\begin{aligned} \mathcal{L}(\Psi) = & \sum_{i=1}^n \log \lambda_{u_i, m_i}(t_i | W_{t_i}) - \sum_{u \in \mathcal{S}} \sum_{m \in \mathcal{M}} \int_0^T \lambda_{u, m}(t | W_t) dt \\ & + \sum_{i=1}^n \log f_{u_i}(v_i | t_i) + \sum_{i=1}^n \log \alpha_{u_i, m_i}(W_{t_i}). \end{aligned} \quad (7)$$

尤度関数からわかる通り、本モデルの最適化問題は $\lambda_{u, m}(t | W_t)$, $f_u(t, v)$, $\alpha_{u, m}(W_t)$ 各々についての独立な最適化問題に帰結する。 $\lambda_{u, m}(t | W_t)$, $\alpha_{u, m}(W_t)$ に関する項は全てのモデルパラメータ Ψ について微分可能なため、勾配を用いた最適化手法を適用することができる。本研究では確率的勾配降下法 (SGD) を用いた。 $f_u(v | t)$ について GNB [8] のパラメータ学習手順に従い、閉形式で解を得ることができる。トリップ時間のモデルに関しても対数正規分布のパラメータ推定の手続きに従い、閉形解を導出することができる。スペースの都合上、パラメータ更新の手順は省略する。

3.4 予測

学習済みの強度関数 $\lambda_{u, m}(t, v | W_t)$ とトリップ時間の分布が与えられた条件の下で未来の任意の時間窓、任意のステーション u におけるトリップ需要 (任意の時間窓における出発イベント数と到着イベント数の期待値) を予測する。

未来の時間窓 $[t_{start}, t_{end}]$ における出発イベント数の期待値は強度関数の積分により得られる。

$$\sum_{m \in \mathcal{M}} \int_{t_{start}}^{t_{end}} \lambda_{u, m}(t | W_t) dt. \quad (8)$$

また、ステーション v における到着イベント数の期待値は次式で定義される到着イベントの強度関数 $\lambda'_v(t | W_t)$ の積分 $\int_{t_{start}}^{t_{end}} \lambda'_v(t | W_t) dt$ で求めることができる。

$$\lambda'_v(t | W_t) = \sum_{u \in \mathcal{S}} \sum_{m \in \mathcal{M}} \int \lambda_{u, m}(t', v | W_t) p_{uv}^m(t - t') dt'. \quad (9)$$

上式の積分は解析的に解くことができないため、数値積分を行う。

4. 実験

4.1 データセット

本研究では 2015 年の 9 月から 2016 年の 8 月にニューヨーク^{*1}, ワシントン D.C.^{*2}, サンフランシスコ^{*3} の 3 都市で観測されたバイクシェアシステムのトリップデータを用いて実験を行う。各々のトリップデータは出発時刻、出発ステーション、到着時刻、到着ステーション、会員種別の系列からなる。実験では、会員種別 (会員・非会員) をユーザ属性として用いる。本研究では、トリップデータに加え weather underground API^{*4} から取得した天気情報を用いた。表 1 に本研究で用いたデータの統計量を示す。

表 1: 実験で用いたデータの基本統計量

データ	NY	D.C.	SF
トリップ	ステーション数	633	402
データ	トリップ数	12,906,339	3,252,709
(会員)		11,367,000	2,581,413
天気	気温 (°C)	[-18, 35]	[-5, 36]
データ	湿度 (%)	[0, 100]	[0, 100]
	視程 (km)	[0, 137]	[0, 48]
	風速 (mph)	[0, 16]	[0, 16]
	降水量 (mm)	[0, 19]	[0, 9]
期間		9/1/2015 - 8/31/2016	

4.2 比較手法

以下の 5 手法を既存手法とし、提案手法との比較を行った。移動平均 (HM) [4] は同じ曜日、時間帯の過去のデータの平均値を予測値とする手法である。Auto-Regressive and Moving Average (ARMA) [5] は時系列データの一手法であり、直近のデータに基づいて予測を行う。Inhomogeneous Poisson Process Inference (IPPI) [1] は点過程ベースの手法であり、出発イベントと到着イベントを独立にモデル化する。その際、時間帯と曜日ごとの周期性を考慮している。Multi-similarity-weighted k-NN (MSWK) [7] は天気と曜日、時間帯の類似性を考慮する k-NN ベースの手法である。Random-forest-based method (RF) [13] は曜日、時間帯と天気を入力として未来のトリップ数を予測する。

4.3 評価指標

予測精度の評価指標として次式で定義される Mean Absolute Error (MAE) を用いた。

$$MAE = \frac{\sum_{u \in \mathcal{S}, t \in \mathcal{T}} \sum_t |\hat{y}_{u,t} - y_{u,t}|}{|\mathcal{T}| |\mathcal{S}|} \quad (10)$$

ここで $\hat{y}_{u,t}$ はステーション u 、時間幅 t における出発・到着イベント数の予測値、 $y_{u,t}$ は観測値である。 \mathcal{T} は予測を行う時間窓の集合、 \mathcal{S} はステーションの集合である。 $|\mathcal{T}|$ は時間窓の個数、 $|\mathcal{S}|$ はステーション数を表す。

年単位の季節性によるバイアスを取り除くため、1 年間のデータ期間を 3 ヶ月ごとに区切り、2015 年 9 月から 11 月、2015 年 12 月から 2016 年 2 月、2016 年 3 月から 5 月、2016 年 6 月から 8 月の 4 つのデータセット各々について学習と予測を行なった。各 3 ヶ月間のデータのうち、各々の最後の 7 日をテストデータ、残りを学習データとして用いた。

4.4 実験結果

図 2 は 6 つの異なる手法に対する MAE を示す。図 2(a) が出発イベント数の予測結果、図 2(b) が到着イベント数の予測結果である。左がニューヨーク、中央がワシントン D.C.、右がサンフランシスコのデータセットに対応している。全てのケースで提案手法が既存手法の予測性能を上回っている。t 檢定の結果、これらの予測精度結果の間に統計的に有意な差があることが示された ($p < 0.01$)。このことから、提案手法はトリップ需要に影響を与える複数の要素 (天気、周期性、出発イベントと到着イベントの関係、会員情報) を適切に考慮していると結論づけることができる。全体として、ARMA は他の手法に比べて精度が低い。これは周期性を考慮していないためと考えられる。出発イベント数の予測においては、天気の情報を考慮する RF, MSWK が過去の履歴のみを用いる HM と同程度の予測精度を出している。特にデータ量が少ないワシントン D.C. とサンフランシスコの 2 つのデータセットでは RF が HM より

*1 <https://www.citibikenyc.com/system-data>

*2 <http://www.capitalbikeshare.com/system-data>

*3 <https://www.fordgobike.com/system-data>

*4 <https://www.wunderground.com/weather/api/>

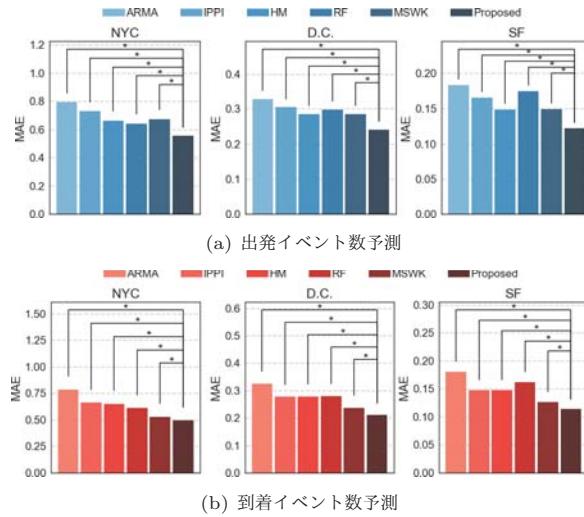


図 2: 出発イベント予測、到着イベント予測に対する Mean absolute error (MAE). 値が小さいほど良い予測性能を示す。

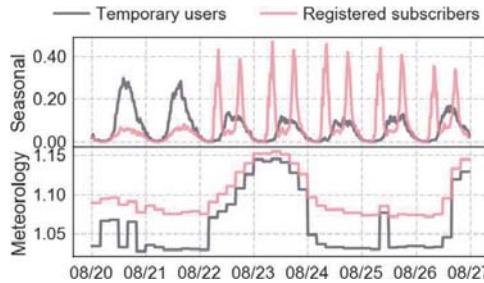


図 3: 学習された強度関数。上の行が周期性を表す項、下の行が天気の影響を表す項に対応する。

り低い性能を示している。提案手法はトリップ需要が時間、天気に対して連続的に変化するという仮定を置いていたため限られた量のデータに対しても頑健に働く。到着イベントの予測については、MSWK, RF と提案手法が他の比較手法より良い予測精度を示している。これは出発イベントと到着イベントの関係を考慮しているためと考えられる。他の評価指標 (Mean Averaged Percentage Error) も用いて評価を行い、類似の結果を得た。

図 3 にワシントン D.C. で最も貸出数の多いステーションで学習された 2016 年 8 月 20 日から 8 月 27 日までの強度関数を示す。一番上の行は周期性を表す項、上段のプロットは天気の影響を表す項である。この図ではピンクの線が非会員、黒の線が会員の強度関数に対応している。会員は主に平日にバイクシェアシステムを利用している。9:00 と 18:00 に通勤需要に対応するピークがある。非会員は主に日中バイクシェアシステムを利用している。また、下段のプロットから非会員の需要は天気によって大きく変動しているのに対し、会員の需要は比較的緩やかに変化している。これらの結果から、会員は非会員に比べて天気の変化の影響を受けにくいということがわかる。提案手法はユーザのタイプによる需要変化の違いについて新たな知見を与える。このような知見は、例えばユーザに対するインセンティブを用いた需要の平準化を行う上で有用である。

5. 結論

本研究では、バイクシェアシステムにおけるトリップ需要の予測に取り組んだ。具体的には、マーク付き点過程を拡張する

ことで(1)周期(2)天気(3)出発ステーションと到着ステーションの関係に加え(4)トリップに付随する情報(会員種別、属性等)を考慮できる新たな手法を構築した。ニューヨーク、ワシントン D.C., サンフランシスコの 3 都市で取得されたバイクシェアシステムのトリップデータを用い、5 つの既存手法と比較することで提案手法の優位性を示した。提案手法は既存手法に比べ、トリップ需要を精度良く予測することができる。また、要素(1)-(4)のトリップ需要への複合的な影響についてより深い知見を与える。

参考文献

- [1] Ramon Alvarez-valdes, Jose M Belenguer, Enrique Bevant, Jose D Bermudez, Enriqueta Vercher, and Francisco Verdejo. Optimizing the level of service quality of a bike-sharing system. *Omega*, 2015.
- [2] U C Davis. Bikesharing in Europe, the Americas, and Asia: Past, Present, and Future. *Europe*, 2010.
- [3] Nan Du, Hanjun Dai, Rakshit Trivedi, Utkarsh Upadhyay, Manuel Gomez-Rodriguez, and Le Song. Recurrent Marked Temporal Point Processes: Embedding Event History to Vector. *KDD*, pages 1555–1564, 2016.
- [4] Jon Froehlich, Joachim Neumann, and Nuria Oliver. Sensing and predicting the pulse of the city through shared biking. *IJCAI*, pages 1420–1426, 2009.
- [5] Andreas Kaltenbrunner, Rodrigo Meza, Jens Grivolla, Joan Codina, and Rafael Banchs. Urban cycles and mobility patterns: Exploring and predicting trends in a bicycle-based public transport system. *Pervasive and Mobile Computing*, 6(4):455–466, 2010.
- [6] Hideaki Kim, Tomoharu Iwata, Yasuhiro Fujiwara, and Naonori Ueda. Read the Silence: Well-timed Recommendation via Admixture Marked Point Processes. *AAAI*, pages 132–139, 2017.
- [7] Junming Liu, Leilei Sun, Weiwei Chen, and Hui Xiong. Rebalancing Bike Sharing Systems: A Multi-source Data Smart Optimization. *KDD*, pages 1005–1014, 2016.
- [8] Tom M Mitchell et al. Machine learning. 1997. *Burr Ridge, IL: McGraw Hill*, 45(37):870–877, 1997.
- [9] Gustavo Romanillos, Martin Zaltz Austwick, Dick Ettema, and Joost De Kruijf. Big data and cycling. *Transport Reviews*, 36(1):114–133, 2016.
- [10] Jasper Schuijbroek, R. C. Hampshire, and W. J. van Hoeve. Inventory rebalancing and vehicle routing in bike sharing systems. *European Journal of Operational Research*, 257(3):992–1004, 2017.
- [11] Adish Singla, Marco Santoni, Gabor Bartok, Pratik Mukerji, Moritz Meenen, and Andreas Krause. Incentivizing Users for Balancing Bike Sharing Systems. *AAAI*, pages 723–729, 2015.
- [12] Pengfei Wang. Human Mobility Synchronization and Trip Purpose Detection with Mixture of Hawkes Processes. *KDD*, pages 495–503, 2017.
- [13] Zidong Yang, Ji Hu, Yuanchao Shu, Peng Cheng, Jiming Chen, and Thomas Moscibroda. Mobility Modeling and Prediction in Bike-Sharing Systems. *MobiSys*, pages 165–178, 2016.
- [14] Jiawei Zhang, Xiao Pan, Moyin Li, and Philip S. Yu. Bicycle-sharing system analysis and trip prediction. *MDM*, pages 174–179, 2016.